

基于深度学习的易拉罐缺陷检测技术

张志晟, 张雷洪

(上海理工大学, 上海 200093)

摘要: **目的** 现有的易拉罐缺陷检测系统在高速生产线中存在错检率和漏检率高, 检测精度相对较低等问题, 为了提高易拉罐缺陷识别的准确性, 使易拉罐生产线实现进一步自动化、智能化, 基于深度学习技术和迁移学习技术, 提出一种适用于易拉罐制造的在线检测的算法。**方法** 利用深度卷积网络提取易拉罐缺陷特征, 通过优化卷积核, 减短易拉罐缺陷检测的时间。针对国内外数据集缺乏食品包装制造的缺陷图像, 构建易拉罐缺陷数据集, 结合预训练网络, 通过调整 VGG16 提升对易拉罐缺陷的识别准确率。**结果** 对易拉罐数据集在卷积神经网络、迁移学习和调整后的预训练网络进行了易拉罐缺陷检测的性能对比, 验证了基于深度学习的易拉罐缺陷检测技术在学习率为 0.0005, 训练 10 个迭代后可达到较好的识别效果, 最终二分类缺陷识别率为 99.7%, 算法耗时 119 ms。**结论** 相较于现有的易拉罐检测算法, 文中提出的基于深度学习的易拉罐检测算法的识别性能更优, 智能化程度更高。同时, 该研究有助于制罐企业利用深度学习等 AI 技术促进智能化生产, 减少人力成本, 符合国家制造业产业升级的策略, 具有一定的实际意义。

关键词: 缺陷检测; 图像评估; 深度学习; 迁移学习; 图像处理

中图分类号: TS807 **文献标识码:** A **文章编号:** 1001-3563(2020)19-0259-08

DOI: 10.19554/j.cnki.1001-3563.2020.19.037

Defect Detection Technology for Cans Based on Deep Learning

ZHANG Zhi-sheng, ZHANG Lei-hong

(University of Shanghai for Science and Technology, Shanghai 200093, China)

ABSTRACT: In allusion to the problem that the existing can defect detection system has high false detection rate and missed detection rate and relatively low detection accuracy in high-speed production lines, this paper aims to propose an algorithm for online detection of can manufacturing based on deep learning and transfer learning techniques to improve the accuracy of can defect identification and make the can production line more automated and intelligent. This paper used deep convolutional network to extract the characteristics of can defects, and optimized the convolution kernel to reduce the time required for can defect detection. Due to the lack of domestic and foreign data sets for defective images of food packaging manufacturing, a can defect data set was built, and the accuracy of identifying can defects was improved by adjusting VGG16 in combination with pre-trained network. The performance comparison for can test was performed on the convolution neural network, transfer learning, and adjusted pre-trained network. It was verified that this technology had a good recognition effect when the learning rate was 0.0005 and the epochs of trainings was 10. The recognition rate of the final binary classification was 99.7% and the time consumption of algorithm was 119 ms. Compared with the existing can detection algorithms, this paper proposes a deep learning-based can detection algorithm with better recognition

收稿日期: 2020-03-04

作者简介: 张志晟 (1994—), 男, 上海理工大学硕士生, 主攻图像识别和印刷包装技术。

通信作者: 张雷洪 (1981—), 男, 博士, 上海理工大学副教授, 主要研究方向为印刷包装技术和数据模拟仿真。

performance and higher intelligence. At the same time, this study helps enterprises to use AI technology such as deep learning to promote intelligent production, reduce human cost, and conform to the strategy of national manufacturing industry upgrading, which has certain practical significance.

KEY WORDS: defect detection; image evaluation; deep learning; transfer learning; image processing

食品安全近年来受到广泛关注,由于易拉罐制造流水线速度不断提升,易拉罐在线检测设备被广泛使用。现有的易拉罐在线检测算法在速度和检测精度上已经可以满足部分制罐厂的需求,但仍存在错检率、漏检率高,智能化程度底等问题。在国内大多数制罐厂易拉罐在线检测设备仍依靠进口,国内设备的识别精度与国外仍有差距。在这种情况下,构建易拉罐缺陷数据集,结合先进的识别技术,快速准确地发现不合格易拉罐,提高易拉罐缺陷算法的识别精度,提升易拉罐在线检测设备性能,有助于解决制罐企业自动化、智能化生产的重大难题。

随着工业制造的高速化,机器视觉已经取代了人眼检测成为了各个制造企业实现自动化生产不可缺少的手段之一。Lecun Y^[1]提出的卷积神经网络(CNN),比传统的BP网络大幅减少了参数和计算,以较强的鲁棒性和特征提取优势超越了传统分类算法。Krizhevsky A^[2]在CNN基础上利用局部神经元和GPU加速等技术实现了深度卷积网络。Han S^[3]通过剪枝、量化和编码等技术再次减少了CNN的权重,加快运行速度,有力推动了其应用。

深度卷积神经网络的发展给识别技术提供了新驱动。Cha Y J等^[4]提出了一种卷积神经网络的深架构用于检测混凝土裂缝,该方案实现了智能检测民用基础设施的缺陷,取代了传统人现场检查,大大提高了效率。Gibert X等^[5]通过深度学习技术自动跟踪检查铁路枕木和紧固件的缺陷减少了人为误差,提高了铁路的安全性。Cheng J.C.P等^[6]应用深度学习技术来检测监视视频中污水管道的缺陷,解决城市建设和城市设施管理的问题。Fang L等^[7]利用深度学习算法评估膝关节图像,实现了智能诊断软骨病变部位。深度学习在制造缺陷检测领域也被广泛研究^[8-18],Zhi C Y等^[19]结合背光成像技术,基于深神经网络提出了一种用于提取和测量手机屏幕缺陷的方法。SHUANGM等^[20]利用高斯金字塔和卷积自编码器构建深度网络可直接逐像素预测织物缺陷。实现了无监督自动化的检测并且定位织物缺陷无需任何人工干预。通过上述

研究可以发现,由于深度学习可并行多项输出任务且具备良好的鲁棒性,其已成为工业自动化、智能化不可缺少的技术之一。

尽管已经有很多学者研究深度神经网络以提高工业产品的缺陷分类性能,但目前大多制罐厂使用的检测设备中仍以最小二乘拟合椭圆方法为主^[21],李光梅、余肇勇等^[22-23]分别对该算法进行过优化,通过拟合的轮廓圆与标准圆对比进行区域定位,再通过模板匹配进行检测。该方法的优点是算法简单,在检测易拉罐罐口时有较大优势,但是,受制罐厂生产环境和生产高速度影响,该方法在易拉罐罐体缺陷和易拉罐底部异物匹配检测时错检率和误检率较高,无法进一步满足制罐厂自动化要求。

深度学习不仅可以弥补现有方法的不足,使制罐厂生产自动化、智能化,可以利用其多输入和输出模型实现更严格食品安全可追溯化,因此,文中提出一种新的解决方法——基于深度学习的易拉罐缺陷在线检测算法,针对易拉罐罐口、罐身和罐底区域的缺陷进行自动化智能检测,通过构建易拉罐数据集,优化卷积核,调整VGG16实现对易拉罐变形、异物等缺陷高速、精确检测。

1 技术原理研究

为实现基于深度学习的易拉罐缺陷分类和智能化判断,主要技术包括缺陷特征提取和基于深度学习的易拉罐合格产品判断,其中优化卷积核,调整VGG16实现对易拉罐缺陷的特征提取是整个设计的核心。

1.1 卷积神经网络

首先将易拉罐流水线上采集到的图像进行裁剪预处理,生成大小相同的图片。再将易拉罐数据集图像输入深层卷积神经网络。文中所使用的深层卷积神经网络的结构见图1,除了输入输出层外,主要为卷积基和全局平均池化层组成,其中卷积基是由多个卷积层(Cov2D)和池化层组成。

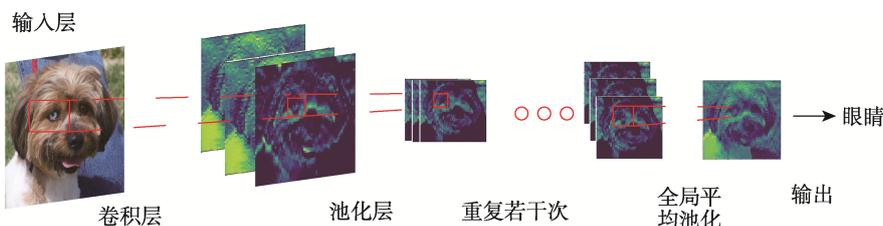


图1 深层卷积神经网络的结构
Fig.1 Structure of a deep convolutional network

卷积过程的一般具体步骤为将输入的易拉罐数字图像作为矩阵，从左上角的 $n \times n$ 子矩阵（一般为 5×5 ）与 $n \times n$ 卷积核进行卷积运算，以 3×3 图像为例，卷积运算过程见图 2，卷积运算见式（1），卷积后得到易拉罐数字图像的特征图。

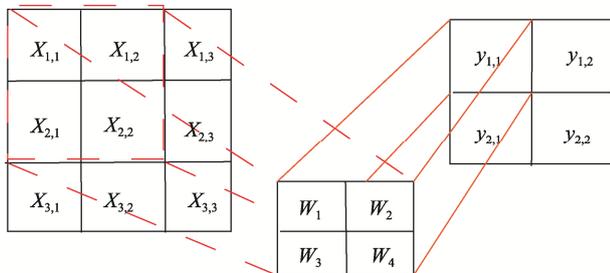


图 2 卷积运算过程
Fig.2 Convolution operation process

$$\begin{aligned}
 y_{1,1} &= W_1 X_{1,1} + W_2 X_{1,2} + W_3 X_{2,1} + W_4 X_{2,2} \\
 y_{1,2} &= W_1 X_{1,2} + W_2 X_{1,3} + W_3 X_{2,2} + W_4 X_{2,3} \\
 y_{2,1} &= W_1 X_{2,1} + W_2 X_{2,2} + W_3 X_{3,1} + W_4 X_{3,2} \\
 y_{2,2} &= W_1 X_{2,2} + W_2 X_{2,3} + W_3 X_{3,2} + W_4 X_{3,3}
 \end{aligned}
 \tag{1}$$

式中： $X_{i,j}$ 为输入图像中相素； $y_{i,j}$ 为特征图中相素； i,j 为相素坐标。

为了加快易拉罐检测速度，将 5×5 的卷积核修改为 3×3 的卷积核，通过减少浮点运算降低乘法消耗。同时利用池化层将易拉罐的特征降维，全局平均池化层对生成的易拉罐的特征图取全局平均值，池化层单元输出见式（2）^[24]。

$$t_{ki}^{out} = f_{sub}(t_{ki}^{in}, t_{k(i+1)}^{in})
 \tag{2}$$

式中： t_{ki}^{out} 为第 k 个特征图的第 i 个单元输出值；

t_{ki}^{in} 为第 k 个输入特征的第 i 个单元输出值； $f_{sub}()$ 为取均值。

1.2 迁移学习

文中使用的易拉罐缺陷数据集属于小型图像数据集，结合迁移学习技术可以有效提高易拉罐缺陷识别精度。迁移学习是指利用已在大型数据集上训练好的参数重新训练新的网络，数据源如果足够大，预训练网络则可以提取图像的深层共通特征。迁移学习的原理见图 3。

对于深层卷积神经网络而言，卷积基部分负责特征提取的任务。将预训练网络中各层特征图之间的卷积基参数迁移至新的易拉罐缺陷检测网络中，可以提高易拉罐图像数据集训练易拉罐缺陷识别任务的精度。

现有的预训练网络大多基于 ImageNet 等自然场景数据集，因此在工业缺陷检测过程中识别精度并不高，需要进行调整。以 VGG16 为例，VGG16 处于顶层的卷积基用来提取图像共通特征，底层卷积基与具体识别任务有关，因此文中不改变 VGG16 顶层权重，重新训练底层权重，通过与分类器联合训练易拉罐缺陷图像，以提高易拉罐缺陷检测精度。

2 方案设计

该设计方法见图 4，方案设计过程主要包含 3 个步骤：易拉罐图像预处理、提取易拉罐缺陷特征、易拉罐产品合格判断。具体内容如下所述。

首先对 ccd 采集到的易拉罐图像进行裁剪，按式（3）进行归一化。

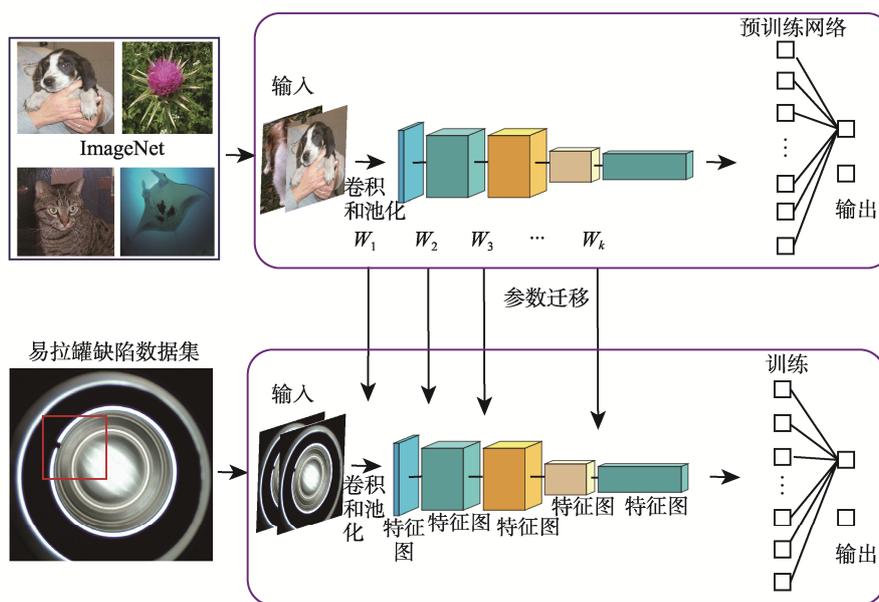


图 3 迁移学习原理
Fig.3 Principles of transfer learning

$$\bar{X} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

式中： x 为相素值； x_{\min} 为易拉罐图像中相素最小的值； x_{\max} 为易拉罐图像中相素最大的值。

将易拉罐图像输入深层卷积网络，该设计顶层以 VGG16 预训练网络为基础，易拉罐图像输入后，卷积层初始化有 64 个神经元，核大小为 3×3 ，步长为 1，最后形成的易拉罐特征图为 (4, 4, 512)，易拉罐特征经过全局平均池化后，连接 2 个全连接层（2 个全连接层神经元均为 512），最后有 2 个输出层负责输出易拉罐缺陷多分类和二分类评价。其中选取激励函数——Relu, Relu 的计算见式 (4)。损失函数见式 (5)，权值更新见式 (6)，为了使损失函数最小化，文中使用优化器——Adam。

$$f_{\text{cov}}(x) = \max(o, x) \quad (4)$$

$$E = \sum_k^h (y_k^i - t_k)^2 \quad (5)$$

式中： y_k^i 为神经元输出； t_k 为期望值。

$$W_{im}^{l-1} = W_{im}^{l-1} - \eta \times \frac{\partial E}{\partial W_{im}^{l-1}} \quad (6)$$

式中： W_{im}^{l-1} 为权值； η 为学习率。

最后通过 Sigmoid 函数和二元交叉熵评价易拉罐产品是否合格，该算法可借助多输出通道，同时输出缺陷的种类和智能的合格判断以提高在易拉罐在线缺陷识别的精准性，缺陷的种类可以帮助制罐厂及时检修制造设备，制罐厂可借助该算法的智能判断在完成不合格易拉罐自动剔除的同时也减少了不必要的误判。

3 构建易拉罐数据集

文中利用现有的异型罐检测仪对易拉罐进行图

像采集，异型罐检测仪主要配件包括相机、LED 光源、光源控制器、64 位系统输出卡。将采集到的易拉罐缺陷图像按上述方法先进行预处理，利用完成预处理的易拉罐图像构建易拉罐缺陷检测数据集。将易拉罐图像进行镜像、旋转等处理后，易拉罐图像共 4000 张，其中 2000 张为不合格的缺陷图像，2000 张为合格图像。编号 1~400 为缺口，编号 401~800 为罐体变形，编号 801~1200 为异物，编号 1201~1600 为底部凹凸，编号 1601~2000 为底部变形。其中缺口为易拉罐罐口缺陷见图 5a，罐体变形为易拉罐罐身缺陷见图 5b，底部凹凸为易拉罐罐底缺陷见图 5c。文中使用中间激活法实现网络可视化，提取易拉罐图像的不同特征，不同易拉罐缺陷图像的典型特征图见图 6。通过观察归类易拉罐特征图可以发现：浅层是对易拉罐图像边缘的探测，保留了大部分易拉罐图像中的信息；随着层数加深，易拉罐特征图抽象化，易拉罐特征图代表“类”的深层信息增加；通过分析易拉罐特征图可知，加深网络层数可提高易拉罐缺陷分类和评估能力。

4 实验仿真及模型分析

为了进一步分析，文中从上述易拉罐数据集中挑选 2000 张图像作为训练集，另外随机选取 2000 张作为测试集。文中利用 python3.0 构建深度网络，再搭建一个卷积神经网络用于对比，通过准确率、耗时和损失值进一步分析网络性能。卷积神经网络结构：输入易拉罐图像，卷积初始化有 64 个神经元，核大小为 5×5 ，步长为 1，共有 6 个卷积层，形成的易拉罐特征图为 (29, 29, 256)，易拉罐特征经过全局平均池化后，为全连接层，全连接层有 1024 个神经元。

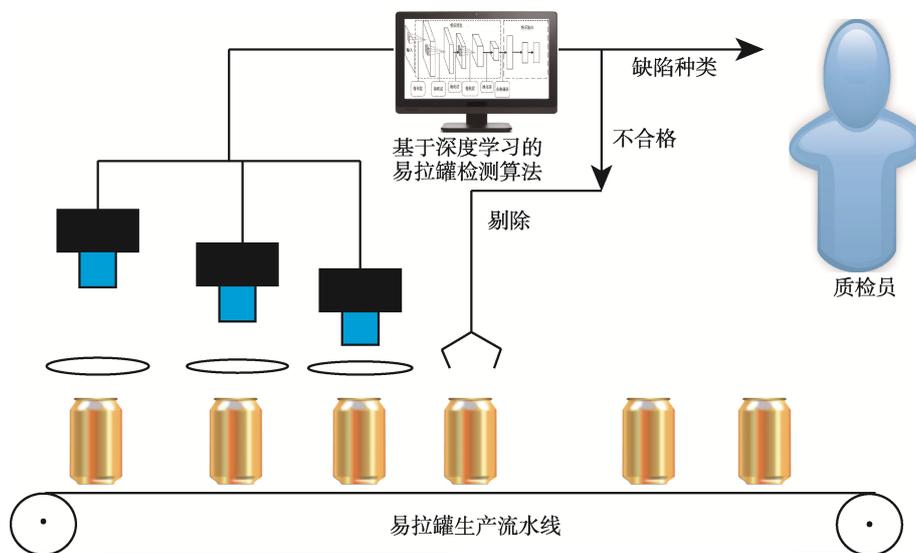


图 4 易拉罐检测流程
Fig.4 Flow chart of can inspection

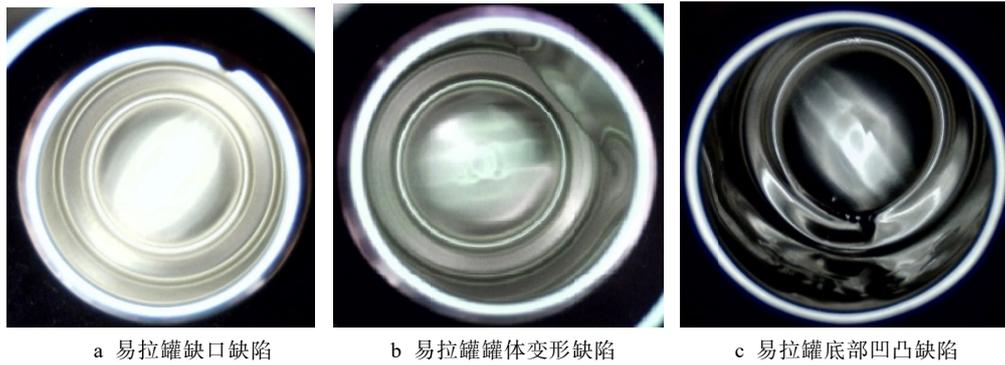


图 5 常见易拉罐缺陷
Fig.5 Common can defects

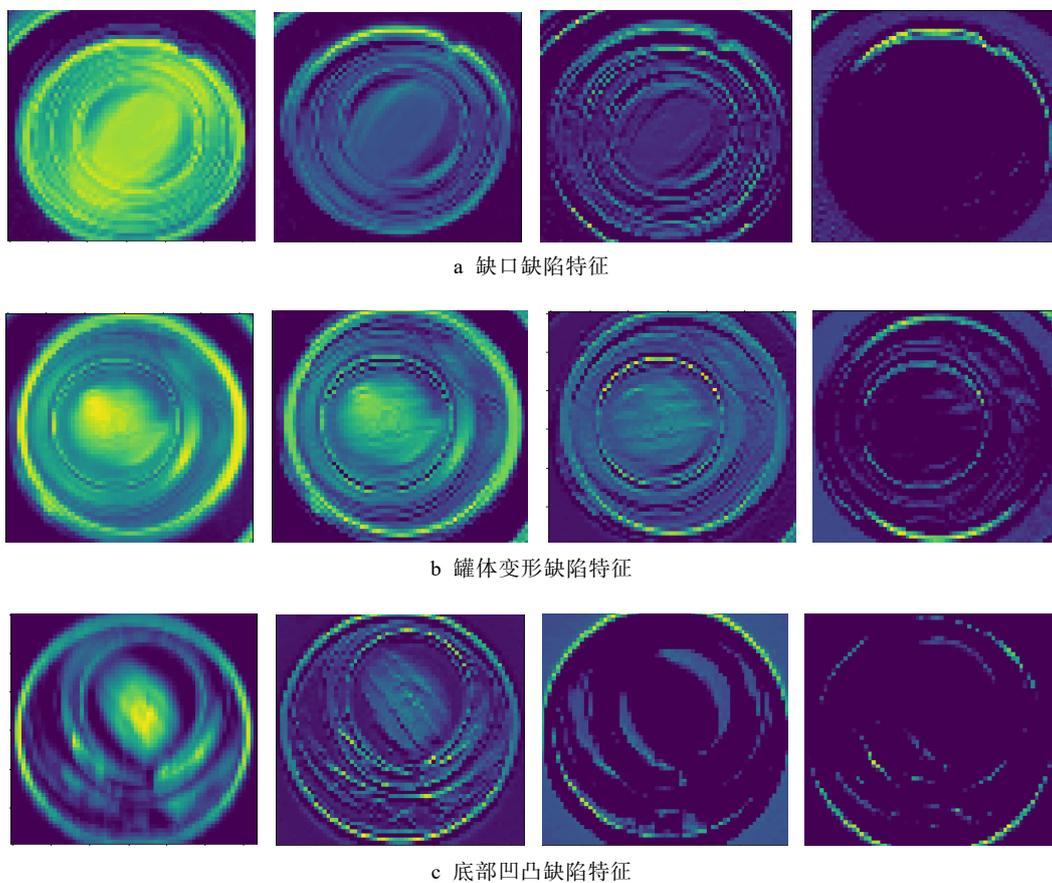


图 6 易拉罐缺陷特征
Fig.6 Defect characteristics of cans

4.1 准确率

为进一步分析模型，本节将通过卷积神经网络与迁移学习进行准确率对比、迁移学习与文中提出的基于深度学习的易拉罐缺陷识别模型进行准确率对比，准确率的计算公式见式(7)，准确率是分类正确的测试数量与所有的测试数之比。在训练和测试网络时将易拉罐图像分批导入，一次迭代 200 张易拉罐图像，学习率为 0.0005 时，卷积神经网络与迁移学习进行易拉罐合格二分类准确率对比结果见图 7。

$$A_{cc} = \frac{T_Y + T_N}{T} \tag{7}$$

式中： A_{cc} 为准确率； T_Y 为实际正确结果； T_N 为实际错误结果； T 为测试集总数。

由图 7 可知，结合迁移学习的易拉罐缺陷检测模型识别率高于卷积网络。不管是在易拉罐图像识别训练集还是测试集，结合迁移学习的易拉罐缺陷检测模型识别率总是比普通的卷积模型高。由于易拉罐数据集规模较小，使用深层卷积模型识别易拉罐缺陷图像无法训练较高的识别效果，不推荐实际易拉罐生产中

使用单纯的卷积模型识别。该次利用的预训练网络是VGG16，基于自然场景下的VGG16对于易拉罐缺陷识别的准确率仍无法达到厂方要求，同时也证明了调整预训练网络的必要性。

调整预训练网络以适用易拉罐检测，VGG16与调整后的基于深度学习的易拉罐识别网络准确率对比见图8，为防止调整模型出现过拟合，因此只选取开始的5次迭代结果与之前VGG16最后5次进行对比。

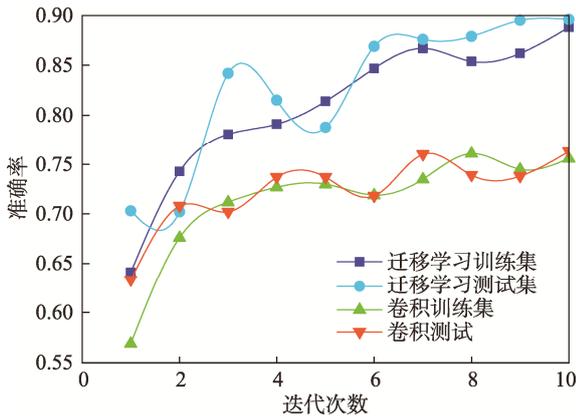


图7 卷积神经网络与迁移学习进行准确率对比

Fig.7 Comparison of accuracy between convolutional neural network and transfer learning

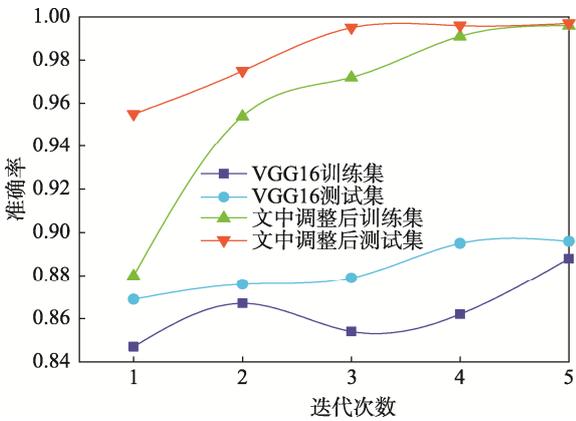


图8 VGG16与调整后的基于深度学习的易拉罐识别网络准确率对比

Fig.8 Comparison of VGG16 and adjusted deep learning-based can recognition network accuracy rates

由图8可知，文中提出的基于深度学习的易拉罐缺陷识别模型比单纯使用VGG16识别易拉罐是否合格要更加准确。文中提出的基于深度学习的易拉罐缺陷识别模型经过训练后可以准确地判断制罐企业生产线上易拉罐产品是否合格。文中提出的基于深度学习的易拉罐缺陷识别模型可以满足制罐厂对易拉罐检测算法的精度要求。该结果可以证明在预训练网络上利用易拉罐数据集微调具有显著效果。

文中提出的基于深度学习的易拉罐缺陷识别模型对于缺陷种类进行多分类的整体识别精度见表1。

表1 易拉罐缺陷多分类识别效果

Tab.1 Multi-class recognition effect of can defects

训练集识别精度/%	测试集识别精度/%
97.5	98.2

文中提出的基于深度学习的易拉罐缺陷识别模型可以对制罐企业生产线上的不合格易拉罐的主要缺陷进行准确的分类，帮助维修员及时检修机器。

4.2 模型耗时

在Win10, NVIDIA, RTX2080TI显卡的pc端下，不同模型识别单张的易拉罐图像消耗时间见图9。

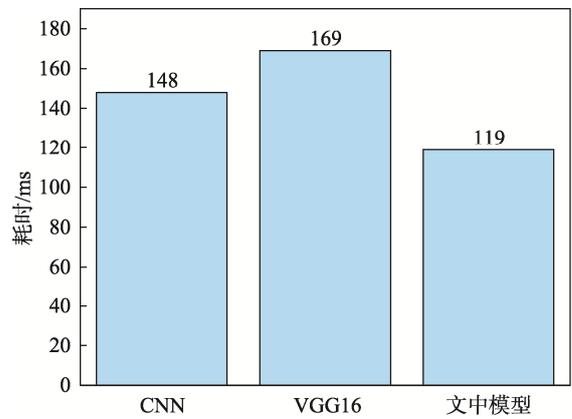


图9 不同模型识别单张的易拉罐图像消耗时间

Fig.9 Consumption time of single can image recognized by different models

由图9可知，优化卷积核后，迁移学习对单幅易拉罐图像检测所用的时间可以降低，文中提出的基于深度学习的易拉罐检测技术可以满足制罐厂对检测设备的响应时间要求。

4.3 损失值

由图10可知，当基于深度学习的易拉罐检测模型在易拉罐训练集上的准确度接近100%时，基于深

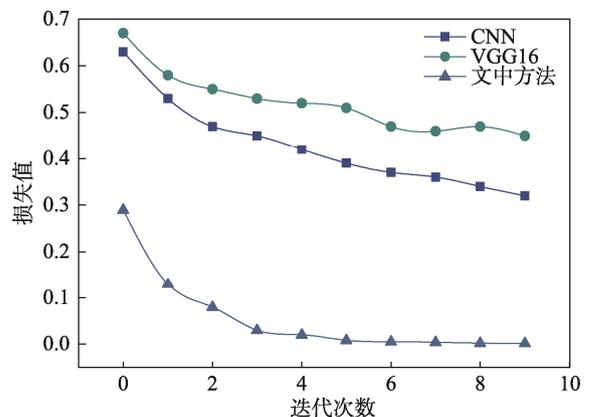


图10 模型损失值对比

Fig.10 Model loss comparison

度学习的易拉罐检测模型损失值在一个较小范围内波动,这说明训练后基于深度学习的易拉罐检测模型趋于平稳,在相同循环下,其他3种模型的训练集的损失函数依旧有较大的波动,说明文中提出的基于深度学习的易拉罐检测模型相对稳定。

5 结语

文中提出了一种基于深度学习的易拉罐检测算法,并对其分类机理进行了研究,解决了现有易拉罐检测算法在易拉罐制造过程中仍存在缺陷识别不精准、不智能等问题。在分类过程中结合迁移学习技术,通过调整 VGG16 能够使检测设备智能判断易拉罐产品情况,提高信息的识别率,从而进一步提高了质检员对于易拉罐缺陷的判断,实现精准的不合格易拉罐分类。文中方法同时适用于易拉罐检测中对于易拉罐罐口、罐身、罐底3部分的缺陷识别,对制罐厂实现自动一体化具有重要的参考意义。该研究有助于制罐企业利用深度学习等 AI 技术促进智能化生产,减少人力成本,符合国家制造业产业升级的策略,具有一定的实际意义。同时有利于进一步扩展人工智能在我国工业制造领域的应用,拥有广阔前景。

参考文献:

- [1] LECUN Y, BENGIO Y, HINTON G. Deep Learning[J]. Nature, 2015, 521(7553): 436.
- [2] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet Classification with Deep Convolutional Neural Networks[J]. Communications of the ACM, 2017, 60(6): 84—90.
- [3] HAN S, LIU X, MAO H, et al. Deep Compression and EIE: Efficient Inference Engine on Compressed Deep Neural Network[C]// 2016 IEEE Hot Chips 28 Symposium (HCS) IEEE, 2016: 1—14.
- [4] CHA Y J, CHOI W. Deep Learning-based Crack Damage Detection Using Convolutional Neural Networks[J]. Computer-aided Civil and Infrastructure Engineering, 2017, 32(5): 361—378.
- [5] GIBERT X, PATEL V M, CHELLAPPA R. Deep Multitask Learning for Railway Track Inspection[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(1): 153—164.
- [6] CHENG J C P, MING Z W. Automated Detection of Sewer Pipe Defects in Closed-circuit Television Images Using Deep Learning Techniques[J]. Automation in Construction, 2018, 95: 155—171.
- [7] LIU F, ZHOU Z Y, SAMSONOV A. Deep Learning Approach for Evaluating Knee MR Images: Achieving High Diagnostic Performance for Cartilage Lesion Detection[J]. Radiology, 2018, 289: 160—169.
- [8] SEKER A, PEKER K A, YUKSEK A G, et al. Fabric Defect Detection Using Deep Learning[C]// 2016 24th Signal Processing and Communication Application Conference (SIU), IEEE, 2016: 7496020—7496024.
- [9] 徐秀, 宣静怡, 曹桐滔, 等. 基于 Faster R-CNN 的圆柱形金属工件表面缺陷检测[J]. 软件导刊, 2019, 18(5): 136—139.
XU Xiu, XUAN Jing-yi, CAO Tong-tao, et al. Surface Defect Detection of Cylindrical Metal Workpieces Based on Faster R-CNN[J]. Journal of Software, 2019, 18(5): 136—139.
- [10] 魏伟, 张磊. 基于深度学习的工业零件缺陷检测算法研究[J]. 信息与电脑(理论版), 2019, 31(18): 32—34.
WEI Wei, ZHANG Lei. Research on Defect Detection Algorithm of Industrial Parts Based on Deep Learning[J]. Information and Computer Science (Theoretical Edition), 2019, 31(18): 32—34.
- [11] 查广丰, 胡泓. 基于深度学习的点胶缺陷检测[J]. 电子技术与软件工程, 2019(13): 49—52.
CHA Guang-feng, HU Hong. Depth Defect Detection Based on Deep Learning[J]. Electronic Technology and Software Engineering, 2019(13): 49—52.
- [12] 徐荣图, 贾明, 宋凝芳. 基于 Faster R-CNN 的保偏光纤偏振轴检测方法研究[J]. 半导体光电, 2018, 39(3): 119—123.
XU Rong-tu, JIA Ming, SONG Ning-fang. Research on Polarization Axis Detection Method of Polarization Maintaining Fiber Based on Faster R-CNN[J]. Semiconductor Optoelectronics, 2018, 39(3): 119—123.
- [13] 姚万业, 李金平. 基于改进的 Faster R-CNN 的电力部件识别[J]. 电力科学与工程, 2019, 35(5): 32—36.
YAO Wan-ye, LI Jin-ping. Power Component Recognition Based on Improved Faster R-CNN[J]. Electric Power Science and Engineering, 2019, 35(5): 32—36.
- [14] 关日钊, 吴磊, 徐焯基. 基于机器视觉的透明塑料件缺陷检测[J]. 装备制造技术, 2018(3): 173—177.
GUAN Ri-zhao, WU Lei, XU Zhuo-ji. Defect Detection of Transparent Plastic Parts Based on Machine Vision[J]. Equipment Manufacturing Technology, 2018(3): 173—177.
- [15] 汪昕, 陈驰, 赵逸凡, 等. 基于深度学习的 API 误用缺陷检测[J]. 软件学报, 2019, 30(5): 144—160.
WANG Xin, CHEN Chi, ZHAO Yi-fan, et al. API Misuse Defect Detection Based on Deep Learning[J]. Journal of Software, 2019, 30(5): 144—160.
- [16] 周建凯, 许盛之, 赵二刚, 等. 基于深度学习的电池片缺陷识别研究[J]. 电子技术应用, 2019, 45(5): 72—75.
ZHOU Jian-kai, XU Sheng-zhi, ZHAO Er-gang, et al. Research on Cell Defect Recognition Based on Deep Learning[J]. Application of Electronic Technique,

- 2019, 45(5): 72—75.
- [17] 李致金, 李培秀, 朱超. 基于深度学习的标签缺陷检测系统应用[J]. 现代电子技术, 2019, 42(7): 161—164.
- LI Zhi-jin, LI Pei-xiu, ZHU Chao. Application of Label Defect Detection System Based on Deep Learning[J]. Modern Electronic Technology, 2019, 42(7): 161—164.
- [18] 毛欣翔, 刘志, 任静茹, 等. 基于深度学习的连铸板坯表面缺陷检测系统[J]. 工业控制计算机, 2019, 32(3): 66—68.
- MAO Xin-xiang, LIU Zhi, REN Jing-ru, et al. Surface Defect Detection System for Continuous Casting Slabs Based on Deep Learning[J]. Industrial Control Computer, 2019, 32(3): 66—68.
- [19] ZHI Chao-yuan, ZHENG Tao. Vision-Based Defect Detection for Mobile Phone Cover Glass using Deep Neural Networks[J]. International Journal of Precision Engineering and Manufacturing, 2018(19): 801—810.
- [20] SHUANG M, YUDAN W, GUO J W. Automatic Fabric Defect Detection with a Multi-scale Convolutional Denoising Autoencoder Network Model[J]. Sensors, 2018, 18(4): 1064—1074.
- [21] 白洁, 马健. LabVIEW Vision 在易拉罐罐口缺陷检测系统的应用[J]. 高校实验室工作研究, 2016(3): 74—75.
- BAI Jie, MA Jian. Application of LabVIEW Vision in Can Defect Detection System for Cans[J]. Laboratory Work Research of Colleges and Universities, 2016(3): 74—75.
- [22] 李光梅, 苟岩岩, 刘果玲. 易拉罐空罐缺陷智能检测系统的设计[J]. 包装与食品机械, 2017, 35(6): 33—36.
- LI Guang-mei, GOU Yan-yan, LIU Guo-ling. Design of Intelligent Detection System for Empty Can Defects in Cans[J]. Packaging and Food Machinery, 2017, 35(6): 33—36.
- [23] 余肇勇, 白仲文, 何炎新. 易拉罐异常检测系统的设计与实现[J]. 科技经济导刊, 2016(14): 31.
- YU Zhao-yong, BAI Zhong-wen, HE Yan-xin. Design and Implementation of Canning Anomaly Detection System[J]. Science & Technology Economics, 2016(14): 31.
- [24] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017(6): 1230—1251.
- ZHOU Fei-yan, JIN Lin-peng, DONG Jun. Review of Convolutional Neural Network Research[J]. Chinese Journal of Computers, 2017(6): 1230—1251.