

基于改进 YOLOv3 的纹理瓷砖缺陷检测

李泽辉^{1,2}, 陈新度^{1,2*}, 黄佳生³, 吴磊^{1,2}, 练洋奇^{1,2}

¹广东工业大学广东省计算机集成制造重点实验室, 广东 广州 510006;

²广东工业大学省部共建精密电子制造技术与装备国家重点实验室, 广东 广州 510006;

³科达制造股份有限公司切割技术事业部, 广东 佛山 528000

摘要 针对目前瓷砖缺陷检测算法主要依赖人工设计特征和分类器, 实际应用中存在调试困难、鲁棒性不足的问题, 提出一种基于改进 YOLOv3 的纹理瓷砖缺陷检测算法。首先, 在 Darknet-53 前加入卷积自编码器, 将瓷砖的弱缺陷重构图像与原输入融合, 得到更丰富的输入信息。然后, 利用 K-means 聚类方法计算新的锚框, 以获得更适合的锚框。最后, 针对小样本问题, 利用在公共数据集上预训练好的权重初始化网络, 以提高模型收敛性能。实验结果表明, 改进后的模型平均准确率提高了 5 个百分点, 基本保持原模型的预测速度, 可以有效检出纹理瓷砖的孔洞及划痕缺陷。

关键词 机器视觉; 图像处理; 缺陷检测; YOLOv3; 自编码器

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP202259.1015006

Defect Detection of Texture Tile Using Improved YOLOv3

Li Zehui^{1,2}, Chen Xindu^{1,2*}, Huang Jiasheng³, Wu Lei^{1,2}, Lian Yangqi^{1,2}

¹Guangdong Provincial Key Laboratory of Computer Integrated Manufacturing, Guangdong University of Technology, Guangzhou 510006, Guangdong, China;

²State Key Laboratory of Precision Electronic Manufacturing Technology and Equipment, Guangdong University of Technology, Guangzhou 510006, Guangdong, China;

³Cutting Technology Department, Keda Industrial Group Co., Ltd., Foshan 528000, Guangdong, China

Abstract The present tile defect detection algorithms mainly rely on manual design features and classifier. In addition, they face debugging difficulties and insufficient robustness in practical applications. Therefore, we proposed a texture tile defect detection algorithm using the improved YOLOv3 model. First, a convolutional autoencoder was added in front of the Darknet-53; the reconstructed images with weak defects were fused with original images to get richer input information. Further, the K-means clustering method was used to get new and more suitable anchors. Finally, to solve the problem of insufficient samples, we used the weights of a pre-trained model trained on a common data set to initialize the network to improve convergence performance. Results show that the average accuracy of the improved model increased by 5 percent, besides it kept the prediction speed of the original model and could effectively detect texture tile holes and scratches.

Key words machine vision; image processing; defect detection; YOLOv3; autoencoder

收稿日期: 2021-03-17; 修回日期: 2021-04-08; 录用日期: 2021-05-21

基金项目: 广东省佛山市产业领域科技攻关项目(2020001006297)、广东省佛山市顺德区核心技术攻关项目(2030218000174)

通信作者: *chenxindu@gdutedu.com.cn

1 引言

我国是瓷砖生产大国,国内的墙地砖生产企业在原料加工方面已实现了机械化和自动化,但在缺陷检测方面大多仍停留在人工检测的水平,检测效率稳定性都难以满足自动化生产要求。在瓷砖的生产流程中,从原料、配方、球磨、制粉、成形、烧制到磨边倒角等,各个环节均会产生不同的缺陷,其中主要包括孔洞、划痕、杂斑等类型表面缺陷^[1]。近年来国内外许多学者提出了基于机器视觉的瓷砖表面缺陷检测方法,早期研究大多采用传统图像处理进行特征提取,然后利用分类器来分类缺陷。如 Ahamad 等^[2]先对瓷砖进行亮度增强和中值滤波的预处理,然后分割瓷砖图像并进行特征提取,最后利用图像直方图检测瓷砖缺陷,实现了对瓷砖缺陷的分类。Hanzaei 等^[3]用旋转不变测量局部方差算子特征提取缺陷特征,经过形态学增强后利用支持向量机进行缺陷分类。艾娇燕^[4]提出一种基于马尔可夫随机场纹理分析的墙地砖色彩缺陷检测方法,而对于孔穴类型缺陷,则利用基于灰度直方图的阈值分割方法进行检测。脱羚^[5]对瓷砖尺寸及表面缺陷开展研究,提出了一种基于多特征融合自适应模糊系统的缺陷检测方法,对瓷砖的黑斑、开裂、釉裂、缺釉、麻面 5 种缺陷进行识别。李小磊等^[6]提出一种基于滑动滤波和形态学处理的陶瓷瓦表面裂纹缺陷检测方法,该方法可以去除光照不均和纹理对裂纹检测的影响。李强等^[7]基于主成分分析(PCA)法对瓷砖图像进行重构,再与原图进行差分,然后利用形态学和二值化方法提取缺陷区域,准确率达 96%。上述方法过于依赖人工设计的特征提取算子,在复杂工业环境中存在鲁棒性不足、硬件调试复杂、算法参数调试困难等缺点^[8]。另一类则是随着深度卷积神经网络发展而出现的目标检测算法,目前深度学习在工业检测领域已经受到了广泛的关注。He 等^[9]提出的基于 Faster-RCNN^[10]的带钢表面缺陷检测网络的各类别平均精确度的平均值(mAP)在缺陷检测数据集 NEU-DET 上达 82.3%。李东洁等^[11]利用融合特征金字塔网络(FPN)的 Faster-RCNN 对马克杯缺陷进行识别,相比原 Faster-RCNN 算法,准确率提高了 2.5%。周君等^[12]提出基于改进 YOLOv3 的织物缺陷实时检测方法,通过对 YOLOv3 模型进行剪枝压缩,在

不改变检测准确率的前提下提高了网络的预测速度。刘露露等^[13]提出了基于 YOLOv3 的布匹瑕疵检测算法,检测准确率可达 89.66%。

基于以上现状,本文针对纹理瓷砖的孔洞及划痕缺陷,提出一种基于改进 YOLOv3 的瓷砖表面缺陷检测方法,利用目标检测的思想解决纹理背景干扰下的孔洞及划痕检测问题,并通过在网络中融合自编码器,提高原 YOLOv3 的准确率。

2 YOLOv3 模型

YOLO^[14]作为目前主流的一阶检测框架于 2016 年 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)中被提出,目的是实现高精度的实时检测。通过将预测框生成和类别预测都转换为回归问题,网络的预测速度相对于 Faster-RCNN 等二阶框架大大加快。目前 YOLOv3 在某些数据集上的检测精度已经逼近二阶检测框架,并且在速度上大幅领先。

2.1 网络主干及多尺度思想

YOLOv3 采用 Darknet-53 作为 backbone 进行特征提取。Darknet-53 由多个 1×1 、 3×3 的卷积层以及残差模块组成,相比 Darknet-19,引入了大量 ResNet 残差模块,网络层数的加深提高了网络对深层语义的提取能力,而且批归一化和残差处理有效防止网络收敛进而出现梯度弥散以及爆炸的问题,与同精度的 ResNet 相比,处理速度也较快^[15-16]。YOLOv3 结合了特征金字塔的思想,利用三个尺度的特征图分别预测不同尺度的物体,小尺度特征图感受野较大用于预测较大的物体,而大尺度的特征图感受野较小用于预测小物体。以 256×256 的输入为例,三个尺度特征图的主要区别在于前两个维度,如第一层特征图是由原输入经 backbone、yoloblock、 3×3 及 1×1 卷积后得到的 32 倍下采样后的特征图,维度为 $8 \times 8 \times [3 \times (4 + 1 + n_c)]$,其中 3 表示三种尺寸的预测框,4 表示预测框的四个位置参数,1 表示预测框置信度, n_c 是预测的类别总数。而第二层特征图是第一层特征图的前两层特征图与 backbone 中对应维度的特征图相拼接后卷积得到的,前两个维度为 16×16 ,其余维度相同。第三层特征图产生原理与第二层相同,前两个维度为 32×32 。

2.2 边框回归

YOLOv3 沿用了 YOLOv2^[17] 相对先验框的位

置进行回归的思想,避免直接相对预测框的框高进行回归,这样使得网络能够回归出精度更高的预测框。其中先验框由训练数据集的标签经过聚类后给出,也就是通过实际框的尺寸来反向推导得到网络可能的预测框尺寸,通过引入先验知识,让网络能够更快学习到更加准确的预测框尺寸,加快模型的收敛速度。预测框的坐标转换原理如图 1 所示。预测框的计算公式为

$$b_x = \sigma(t_x) + c_x, \quad (1)$$

$$b_y = \sigma(t_y) + c_y, \quad (2)$$

$$b_w = p_w e^{t_w}, \quad (3)$$

$$b_h = p_h e^{t_h}, \quad (4)$$

式中: c_x, c_y 表示预测目标矩形框中心点左上角点在特征图中的坐标; t_x, t_y 表示预测坐标的偏移量; t_w, t_h 表示预测框的宽高尺度缩放因子; p_w, p_h 是预设锚框的宽高在特征图尺度下的映射值。




图 1 预测框坐标转换

Fig. 1 Coordinate transformation of bounding box

3 改进的 YOLOv3 模型

3.1 融合 CAE 模块的网络主干改进

与常见的目标检测方案中如车辆、行人检测等复杂场景相比,缺陷检测中的背景区域相对来说可以理解为一种确定的纹理模式。拿随机纹理的瓷砖来说,同一类不同块的瓷砖图像虽然在像素差异上是绝对不同的,但人可以清楚地知道这是一类花纹颜色的瓷砖^[18],所以说一种类型的瓷砖纹理存在相应的纹理表达模型。目前有一些图像修复方面的技术被应用于异常检测,如生成对抗网络(GAN)及卷积自编码器(CAE)等被用于从无缺陷样本中提取正常纹理模式,然后对待测样本的异常区域进行修复以获得无异常的重构图片,通过比对两者之间的像素差异可以凸显出异常区

域。基于该思想,本文在 YOLOv3 的 Darknet-53 前端加入卷积自编码器,利用卷积自编码器对原图像进行弱缺陷重构,然后将重构图像张量与原输入张量拼接后再输入 Darknet-53,旨在使网络可以从增强的输入中学习到这种异常变化,以实现缺陷检测。

卷积自编码器由自编码器发展而来,采用卷积操作替代了原先的非线性函数来对数据进行特征编码和特征解码操作^[19]。卷积自编码器主要包含特征编码和解码模块,其中编码模块由若干卷积以及池化层组成,解码模块由若干反卷积层组成。编码模块 ϕ 和解码模块 ψ 可以表示为

$$\phi, \psi = \operatorname{argmin} \| \mathbf{x} - \psi[\phi(\mathbf{x})] \|^2, \quad (5)$$

式中: $\mathbf{x} \in X, \mathbf{x}$ 表示图像样本空间 X 中的一个图像块,通过编码过程 ϕ 映射到图像样本特征空间 F 中,然后再通过解码过程 ψ 映射回原 \mathbf{x} 所在空间域。设重构后的图像块为 $\mathbf{x}', \mathbf{z} = \phi(\mathbf{x}) \in F$,则编码和解码可分别表示为

$$\mathbf{z} = \sigma(\mathbf{W} \circ \mathbf{x} + \mathbf{b}), \quad (6)$$

$$\mathbf{x}' = \sigma(\mathbf{W}' \circ \mathbf{z} + \mathbf{b}'), \quad (7)$$

式中: \circ 表示卷积运算; σ 表示激活函数; \mathbf{W} 和 \mathbf{W}' 分别表示卷积和反卷积权值矩阵; \mathbf{b} 和 \mathbf{b}' 表示偏置向量。

为了不对网络引入过多的参数量,本文搭建轻量化的 CAE 模块对图像进行弱缺陷重构,CAE 模块结构如图 2 所示,左侧为特征编码模块,由三个卷积层及最大池化层组成,右侧为特征解码模块。为了消除反卷积产生的棋盘格效应,解码操作中采用双线性插值上采样层接卷积层代替反卷积层;随后将重构后的图像张量与网络 backbone 前的输入以 concat 的形式相接即通道数增加,同时加入残差模块防止网络退化;最后再进入 Darknet-53。

CAE 模块的输出是重构图像,故在训练策略与损失函数选取上与目标检测任务不同,为了更好地衡量生成图像与原图之间的差异,采取结构相似性衡量函数(SSIM)^[20-21]构造新的损失以代替常用的均方误差损失(MSE)。相比 MSE 直接计算各像素差异,SSIM 综合考虑了图像在亮度、对比度、结构三方面的相似性。亮度相似性 l 、对比度相似性 c 、结构相似性 s 、最终的 SSIM 可以表示为

$$l(a, b) = \frac{2\mu_a\mu_b + C_1}{\mu_a^2 + \mu_b^2 + C_1}, \quad (8)$$




图 2 卷积自编码器结构
Fig. 2 CAE structure

$$c(a, b) = \frac{2\sigma_a\sigma_b + C_2}{\sigma_a^2 + \sigma_b^2 + C_2}, \quad (9)$$

$$s(a, b) = \frac{\sigma_{ab} + C_3}{\sigma_a\sigma_b + C_3}, \quad (10)$$

$$S_{SIM}(a, b) = [l(a, b)^\alpha \cdot c(a, b)^\beta \cdot s(a, b)^\gamma], \quad (11)$$

式中： μ 和 σ 分别表示图像的均值和标准差； $\alpha > 0$ ， $\beta > 0$ ， $\gamma > 0$ ， C 是非零常数，通常取 $\alpha = \beta = \gamma = 1$ ；SSIM 损失表示为 $1 - S_{SIM}$ 。加入了 CAE 模块后，需要将 CAE 模块与目标检测任务分开训练，即首先利用无缺陷图像对 CAE 模块进行训练以获得对正常纹理的重构能力，然后对主网络中的 CAE 模块进行冻结，并导入之前预训练好的 CAE 权重，最后再在整个缺陷数据集上进行目标检测任务的训练。具体训练流程如图 3 所示。改进后网络的整体特征提取结构及数据流传输结构如图 4 所示。

3.2 锚框(anchors)选取改进

网络的默认 anchors 尺寸是针对 COCO 数据集聚类得到的，而孔洞、划痕缺陷尺寸相对 COCO 数据集来说较小且形状类型也较少，图 5 展示了本文数据集中缺陷目标的宽高分布，其中 w 为宽， h 为高。为了提高网络的检测性能，需要对网络设置新的 anchors 尺寸。采取 K-means 聚类方法^[22]来对瓷砖缺陷的标注宽高进行聚类。不同于普通基于欧氏距离的聚类，锚框聚类需要同时考虑聚类框之间的重叠度。因为如果单纯考虑锚框长宽之间的差异，则对较大的锚框之间计算欧氏距离时产生的误差会比小锚框更大，故将所有锚框的中心点坐标都设为(0,0)，然后计算每个框之间的交并比(IOU)来作为新的距离衡量准则，计算方法为

$$d(G_{\text{box}}, C_{\text{cen}}) = 1 - \text{IOU}(G_{\text{box}}, C_{\text{cen}}), \quad (12)$$

式中： d 表示距离； G_{box} 表示标注框； C_{cen} 表示聚类中

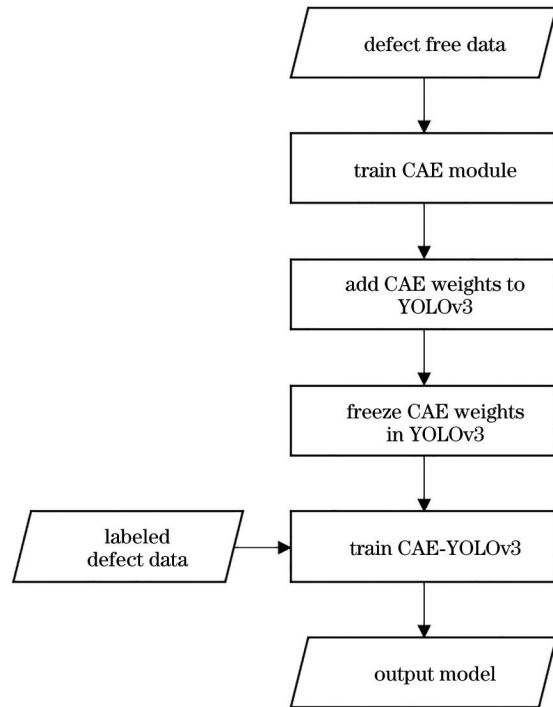


图 3 所提网络训练流程

Fig. 3 Training process of the proposed network

心框。式(12)表明两个框之间交并比越大，两个框尺寸越接近。由于本文保留了原 YOLOv3 的三个尺度特征图预测结构，故聚类中选取簇类别数为 9。为了避免初始点对聚类结果的影响，取 10 次聚类结果然后选取平均 IOU 最大的那组作为最终结果，实验中最后选的 9 个锚框为 [(10, 17), (24, 23), (39, 49), (11, 11), (38, 37), (15, 13), (29, 34), (64, 75), (17, 18)]。根据面积大小进行排序，然后按照大小顺序均分到三个尺度的特征图中作为预设 anchors，小的锚框结合大的特征图来预测小目标缺陷，中等大小的锚框结合中间特征图预测中等面积缺陷，大锚框结合小的特征图来预测较大的缺陷。

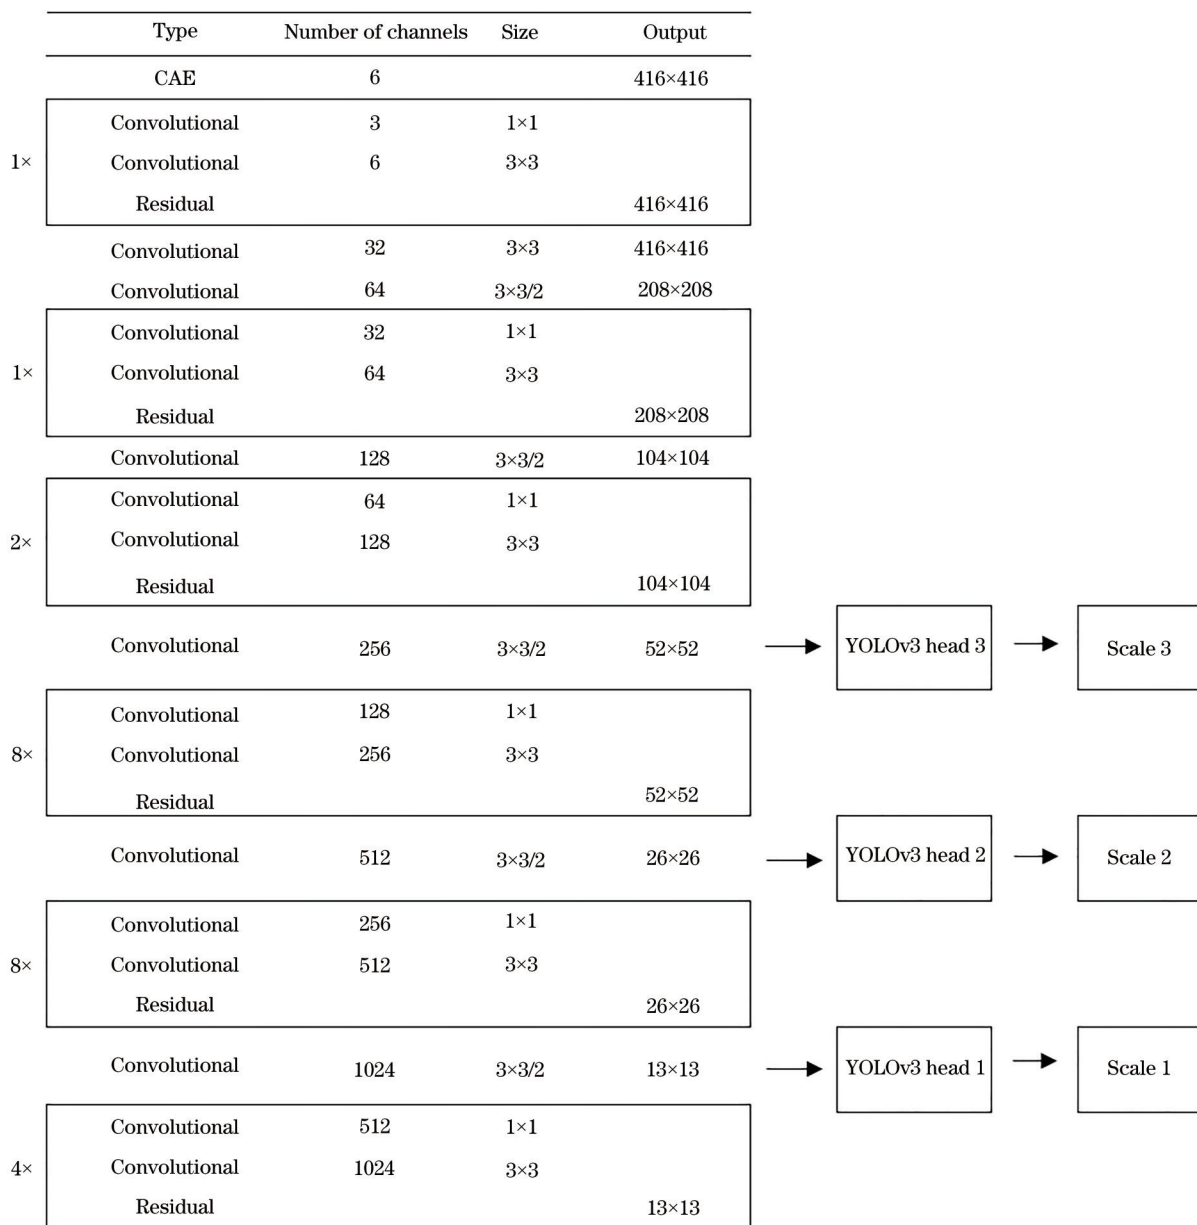


图 4 改进后的 YOLOv3 主干
Fig. 4 Improved YOLOv3 backbone




图 5 数据集标注框分析
Fig. 5 Analysis of ground truth of the dataset

4 实验结果与分析

4.1 实验配置及数据获取

搭建配置为：操作系统 Ubuntu20.04，显卡 NVIDIA GTX1060，显存 6 G，内存 16 G，神经网络库 Pytorch1.7。

数据集为在瓷砖生产企业采集的随机纹理瓷砖，瓷砖表面缺陷如图 6 所示，包括孔洞、划痕及洞三种类型缺陷。采集到的瓷砖图像包含一些非感兴趣区域，为了避免多余的检测，适应网络的输入，将原图分割成 416×416 分辨率的切片图像，然后取




图 6 瓷砖缺陷图像。(a)孔洞;(b)划痕;(c)洞

Fig. 6 Images of tile's defect. (a) Pinhole; (b) crack; (c) hole

出其中带有缺陷的切片图像进行标注。在深度模型训练中,数据集的作用直接影响模型的收敛结果,在有限的实验样本情况下,通常使用数据增强来对数据集作一定小的改变来扩充数据,使用增强后的数据训练网络可以使得网络获得更强的泛化能力,通常的数据增强方式有旋转缩放、剪切、饱和度及亮度拉伸。通过添加轻度高斯噪声、镜像、位置变换操作对数据集进行扩充,网络可以学习到更加丰富的缺陷分布信息,最后得到数据样本约 1000

张,以 8:2 的比例划分训练集和测试集。

4.2 模型训练与评估

加入 CAE 模块之后的模型训练分为两步,第一步需要对 CAE 模块进行训练,采用 388 张无缺陷的瓷砖分块图像对 CAE 模块进行训练,迭代 1 次后停止训练,此时 SSIM 损失约为 0.85。实验中若训练迭代次数增加,则会导致 CAE 过拟合出缺陷区域。图 7 展示了经过 CAE 模块后得到的重构图像,可以看出重构后的缺陷区域与原图有较大差异。




图 7 重构结果。(a)原图 1;(b)重构图 1;(c)原图 2;(d)重构图 2

Fig. 7 Results of reconstruction. (a) Source image 1; (b) reconstruction image 1; (c) source image 2; (d) reconstruction image 2

第二步需要对整个目标检测网络进行训练,考虑到瓷砖缺陷数据集相对 COCO 数据集来说较小,有可能无法拟合整个网络,使用预训练模型可以使网络获得较好的初始权重,加快网络的收敛速度。故基于迁移学习的思想,利用原 YOLOv3 模型在 COCO 数据集上预训练得到的浅层 backbone 权重初始化改进后的模型的对应权重,以加快网络收敛性能。设置了两组实验来验证迁移学习的有效性,实验 1 采用随机权重初始化网络,实验 2 采用在公共数据集上的预训练权重初始化网络。设置同样的优化器和迭代参数,迭代 400 次后绘制出 loss-epoch 曲线,如图 8 所示,可以看到方法 2 由于一开始就具有较优的浅层权重,模型收敛曲线较为平稳,最终的 loss 也更加小,说明导入预训练权重有利

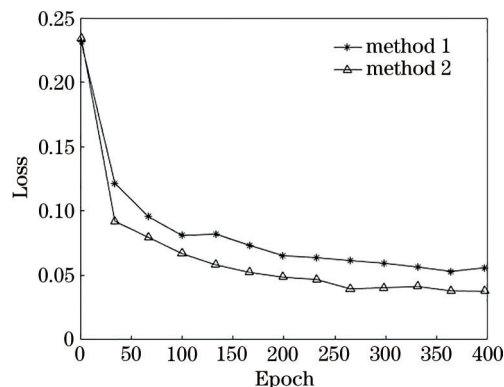


图 8 损失-迭代曲线

Fig. 8 Loss-epoch curve

于瓷砖缺陷检测模型的训练。

为了验证改进后网络的预测性能,设置了两组

对比实验,均使用相同的数据。本文采用不同 IOU 阈值下的精确率和召回率来计算平均 mAP 以衡量模型的预测性能,采用平均每秒处理帧率(FPS)来评价网络的预测速度。表 1 为两者的性能对比,相比没改进的 YOLOv3 模型, YOLOv3+CAE 在处理单张图片的时间上比原模型慢了约 0.02 s,但平均准确率提高了约 5 个百分点。

表 1 模型性能对比

Table 1 Comparison of model performance

Method	mAP(IOU is 0.5) / %	mAP(IOU is 0.95) / %	Avg FPS / (frame·s ⁻¹)
YOLOv3	78.37	59.48	11.49
YOLOv3+CAE	83.49	68.10	8.85

图 9 展示了 YOLOv3+CAE 的检测结果,改进后的模型在预测精度度以及预测框与实际框的重叠率上也更高,可以有效检出瓷砖表面缺陷。




图 9 检测结果对比。(a) YOLOv3 检测结果;
(b) YOLOv3+CAE 检测结果

Fig. 9 Comparison of test results. (a) YOLOv3 test result;
(b) YOLOv3+CAE test result

为了进一步说明网络的鲁棒性和预测效果,本文设置了两组实验:第一组实验中选取了分辨率为 1500×1500 的瓷砖缺陷图像,并经过一定的亮度扰动后输入网络;第二组实验则是先对多张分辨率为 416×416 的瓷砖缺陷图像进行随机旋转、对比度变换或者模糊处理,然后拼接后输入网络。实验结果如图 10 所示,可以看到网络具有一定程度抗干扰性能,此外网络对较大分辨率的输入依然能够取得良




图 10 对比实验。(a)1500×1500 分辨率原图;(b)亮度扰动 1;
(c)亮度扰动 2;(d)拼接图像

Fig. 10 Comparison experiment. (a) Original image with 1500×1500 resolution; (b) brightness disturbance 1; (c) brightness disturbance 2; (d) stitched image

好的预测效果。

5 结 论

以随机纹理瓷砖为研究对象,为了实现瓷砖缺陷的实时检测,结合当前较为优秀的实时检测网络 YOLOv3 并对其进行改进,通过在原模型基础上添加 CAE 模块并针对瓷砖缺陷重新选取预设锚框,从异常检测的角度去利用目标检测网络来实现纹理背景下的缺陷检测。融合 CAE 模块的 YOLOv3 网络在 mAP 上提高了 5 个百分点,在速度上单张图像处理时间虽然慢了 0.02 s 但仍具有优秀的速度。所提网络为后续瓷砖在线检测提供了一种方法思路,但也存在许多改进空间,对瓷砖进行分块训练后如何在大分辨率图像上实现预测仍值得考虑,未来将针对网络规模压缩,在保证精度同时提高预测速度方面进行进一步研究。

参 考 文 献

[1] 李军华, 权小霞, 汪宇玲. 多特征融合的瓷砖表面缺陷检测算法研究[J]. 计算机工程与应用, 2020, 56(15): 191-198.
Li J H, Quan X X, Wang Y L. Research on defect detection algorithm of ceramic tile surface with multi-feature fusion[J]. Computer Engineering and

- Applications, 2020, 56(15): 191-198.
- [2] Ahamad N S, Rao J B. Analysis and detection of surface defects in ceramic tile using image processing techniques[M]//Satapathy S C, Rao N B, Kumar S S, et al. Microelectronics, electromagnetics and telecommunications. Lecture notes in electrical engineering. New Delhi: Springer, 2016, 372: 575-582.
- [3] Hanzaei S H, Afshar A, Barazandeh F. Automatic detection and classification of the ceramic tiles' surface defects[J]. Pattern Recognition, 2017, 66: 174-189.
- [4] 艾娇燕. 基于计算机视觉的墙地砖颜色分类和缺陷检测研究[D]. 广州: 华南理工大学, 2003: 10-12.
Ai J Y. Research on color grading and defect detection of the tiles based on computer vision[D]. Guangzhou: South China University of Technology, 2003: 10-12.
- [5] 脱羚. 基于多特征信息融合的陶瓷砖表面质量在线检测方法研究[D]. 西安: 陕西科技大学, 2019: 41-43.
Tuo L. Research on online detection method of ceramic tiles surface quality based on multi-feature fusion[D]. Xi'an: Shaanxi University of Science & Technology, 2019: 41-43.
- [6] 李小磊, 曾曙光, 郑胜, 等. 基于滑动滤波和自动区域生长的陶瓷瓦表面裂纹检测[J]. 激光与光电子学进展, 2019, 56(21): 211003.
Li X L, Zeng S G, Zheng S, et al. Surface crack detection of ceramic tile based on sliding filter and automatic region growth[J]. Laser & Optoelectronics Progress, 2019, 56(21): 211003.
- [7] 李强, 曾曙光, 郑胜, 等. 基于机器视觉的陶瓷瓦表面裂纹检测方法[J]. 激光与光电子学进展, 2020, 57(8): 081004.
Li Q, Zeng S G, Zheng S, et al. Machine vision based detection method for surface crack of ceramic tile[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081004.
- [8] 陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报, 2021, 47(5): 1017-1034.
Tao X, Hou W, Xu D. A survey of surface defect detection methods based on deep learning[J]. Acta Automatica Sinica, 2021, 47(5): 1017-1034.
- [9] He Y, Song K C, Meng Q G, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1493-1504.
- [10] Ren S Q, He K M, 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): 1137-1149.
- [11] 李东洁, 李若昊. 基于改进 Faster RCNN 的马克杯缺陷检测方法[J]. 激光与光电子学进展, 2020, 57(4): 041515.
Li D J, Li R H. Mug defect detection method based on improved Faster RCNN[J]. Laser & Optoelectronics Progress, 2020, 57(4): 041515.
- [12] 周君, 景军锋, 张缓缓, 等. 基于 S-YOLOV3 模型的织物实时缺陷检测算法[J]. 激光与光电子学进展, 2020, 57(16): 161001.
Zhou J, Jing J F, Zhang H H, et al. Real-time fabric defect detection algorithm based on S-YOLOV3 model[J]. Laser & Optoelectronics Progress, 2020, 57(16): 161001.
- [13] 刘露露, 李波, 何征, 等. 基于 FS-YOLOv3 及多尺度特征融合的棉布瑕疵检测[J]. 中南民族大学学报(自然科学版), 2021, 40(1): 95-101.
Liu L L, Li B, He Z, et al. Cotton defect detection based on FS-YOLOv3 and multiscale feature fusion[J]. Journal of South-Central University for Nationalities (Natural Science Edition), 2021, 40(1): 95-101.
- [14] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [15] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08) [2020-04-02]. <https://arxiv.org/abs/1804.02767>.
- [16] 卢官有, 顾正弘. 改进的 YOLOv3 安检包裹中危险品检测算法[J]. 计算机应用与软件, 2021, 38(1): 197-204.
Lu G Y, Gu Z H. A dangerous goods detection algorithm based on improved YOLOv3[J]. Computer Applications and Software, 2021, 38(1): 197-204.
- [17] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [18] 强振平, 何丽波, 陈旭, 等. 深度学习图像修复方法综述[J]. 中国图象图形学报, 2019, 24(3): 447-463.

- Qiang Z P, He L B, Chen X, et al. Survey on deep learning image inpainting methods[J]. *Journal of Image and Graphics*, 2019, 24(3): 447-463.
- [19] 袁非牛, 章琳, 史劲亭, 等. 自编码神经网络理论及应用综述[J]. *计算机学报*, 2019, 42(1): 203-230.
- Yuan F N, Zhang L, Shi J T, et al. Theories and applications of auto-encoder neural networks: a literature survey[J]. *Chinese Journal of Computers*, 2019, 42(1): 203-230.
- [20] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society*, 2004, 13(4): 600-612.
- [21] 余文勇, 张阳, 姚海明, 等. 基于轻量化重构网络的表面缺陷视觉检测[J/OL]. *自动化学报*, 1-15[2021-03-16]. <https://doi.org/10.16383/j.aas.c200535>.
- Yu W Y, Zhang Y, Yao H M, et al. Visual inspection of surface defects based on lightweight reconstruction network[J/OL]. *Acta Automatica Sinica*, 1-15[2021-03-16]. <https://doi.org/10.16383/j.aas.c200535>.
- [22] Celebi M E, Kingravi H A, Vela P A. A comparative study of efficient initialization methods for the k-means clustering algorithm[J]. *Expert Systems With Applications*, 2013, 40(1): 200-210.