DOI: 10.13382/j. jemi. B2306965

# 融合深度迁移学习和改进 ThunderNet 的 瓷砖表面缺陷检测<sup>\*</sup>

陈克琼! 卓士虎! 赵晨曦! 傅立涛! 王家铭! 李帷韬2

(1. 合肥大学先进制造工程学院 合肥 230601;2. 合肥工业大学电气与自动化工程学院 合肥 230009)

摘 要:瓷砖生产过程中由于环境的复杂性和随机性导致缺陷特性各异,实际中要构建大规模、高质量的瓷砖表面缺陷数据样本非常困难,而小样本条件下的可分特征信息不足对瓷砖表面缺陷检测的精度有较大影响。针对这一问题,探索了一种融合深度迁移学习和改进两阶段 ThunderNet 网络的瓷砖表面缺陷检测方法。首先,提出了一种基于改进 ThunderNet 网络的瓷砖表面缺陷检测模型,阐述了模型的结构与功能特点;其次,构造了瓷砖表面缺陷深度特征空间参数迁移决策机制,以有效提升样本特征表征能力;第三,基于可切换空洞卷积(switchable atrous convolution, SAC)优化 ShuffleNet 骨干网络,增强模型对缺陷形状变化的学习能力;第四,提出了基于多尺度映射和通道注意力(squeeze and excitation, SE)的特征融合算法,实现有限特征层次中瓷砖表面缺陷特征信息多层次差异化表征;最后,给出了融合深度迁移学习和改进 ThunderNet 网络的瓷砖表面缺陷无状变化的学习能力;第四,提出了基于多尺度映射和通道注意力(squeeze and excitation, SE)的特征融合算法,实现有限特征层次中瓷砖表面缺陷特征信息多层次差异化表征;最后,给出了融合深度迁移学习和改进 ThunderNet 网络的瓷砖表面缺陷测试集上,本文方法对于小样本条件下瓷砖表面缺陷检测具有优越的性能,模型平均精度、平均召回率和平均检测速度分别达到 87.22% 93.69% 61.6 ms/img,与传统 ThunderNet 模型相比,平均精度和平均召回率分别提高了 9.30%、4.16%,其中,基于 SAC 最优空洞率组合 1,2 ,模型精度提高了 5.51%,基于 SE 的最优压缩率 24,模型精度提高了 6.16%,基于本文迁移机制,模型精度提高了 3.86%,同时加速了网络收敛。本文方法相比于传统 ThunderNet 网络和其他主流检测模型,通过迁移机制知识共享提高小样本对象特征表达能力,通过引入 SAC 和 SE 在控制模型规模的前提下实现对象特征的层次化表征,有效提升了模型的实时性和可靠性。

# Integrated deep transfer learning and improved ThunderNet in tile surface defect detection

Chen Keqiong<sup>1</sup> Zhuo Shihu<sup>1</sup> Zhao Chenxi<sup>1</sup> Fu Litao<sup>1</sup> Wang Jiaming<sup>1</sup> Li Weitao<sup>2</sup>

(1. School of Advanced Manufacturing Engineering, Hefei University, Hefei 230601, China;

2. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

Abstract: Due to the complexity and randomness of the environment in the production process of ceramic tiles, it is very difficult to construct large-scale and high-quality ceramic tile surface defect data samples, and the insufficient distinguishable feature information under few-shot conditions has a great impact on the accuracy of ceramic tile surface defect detection. To solve this problem, a tile surface defect detection method based on deep transfer learning and improved two-stage ThunderNet network is explored. Firstly, a tile surface defect detection model based on the improved ThunderNet network is proposed, and the structure and functional characteristics of the model are elaborated. Secondly, the decision-making mechanism for spatial parameter transfer of tile surface defect detectively improve the characterization ability of sample feature. Third, the ShuffleNet backbone network is optimized based on Switchable Atrous Convolution (SAC) to enhance the model's learning ability to the changeable shape of defects. Fourth, a feature fusion algorithm based on multi-scale mapping and squeeze and excitation (SE) is proposed to realize the multi-level differentiated characterization of tile surface defect feature information in a limited feature level. Finally, a tile surface defect detection

收稿日期: 2023-10-16 Received Date: 2023-10-16

\*基金项目:国家自然科学基金(62173120)、安徽省自然科学基金青年项目(1908085QF270)、安徽省高等学校科学研究项目(自然科学类)重点 项目(2022AH051793)资助

algorithm for fusion deep transfer learning and improved ThunderNet network is given. The experimental data show that on the same tile surface defect test dataset, the proposed method has superior performance for the detection of tile surface defects under few-shot conditions, and the average accuracy, average recall and average detection speed of the model reach 87.22%, 93.69% and 61.6 ms/img, respectively, compared with the traditional ThunderNet model, the average accuracy and average recall are improved by 9.30% and 4.16%, respectively, among which, based on the SAC optimal atrous ratio combination  $\{1,2\}$ , The model accuracy is improved by 5.51%, the model accuracy is improved by 6.16% based on the optimal compression ratio of SE 24, and the model accuracy is improved by 3.86% based on the transfer mechanism in this paper, and the network convergence is accelerated. Compared with the traditional ThunderNet network and other mainstream detection models, the proposed method improves the expression ability of few-shot object features through knowledge sharing of transfer mechanism, and realizes hierarchical representation of object features by introducing SAC and SE under the premise of controlling the scale of the model, which effectively improves the real-time reliability and reliability of the model.

Keywords: tile surface defect detection; switchable atrous convolution; transfer learning; channel attention; feature fusion; few-shot

# 0 引 言

瓷砖作为生活中重要的装饰材料,由于在生产过程 中难免出现形态多变的各种瑕疵,这给瓷砖表面缺陷检 测带来了极大的挑战[1]。传统的人工检测方法根据人的 主观决策给出缺陷检测结果,检测效率及精度难以保证, 检测结果缺乏客观性和一致性。随着信息技术的迅速发 展,采用图像处理算法、神经网络等技术方法实现瓷砖表 检受到了广泛关注。文献提出一种显著区域检测算 法<sup>[2]</sup>,对缺陷图像进行超像素分割并以缺陷颜色和结构 差异构建显著性图,利用连通域法确定显著区域实现对 缺陷准确检测:文献提出一种基于激光三角剖分方法 (laser triangulation method, LTM)<sup>[3]</sup>构建瓷砖表面三维图 像.并设计了图像滤波和缺陷识别的瓷砖三维表面图像 分析算法,针对选定的缺陷给出了缺陷参数的测量方法 和表面缺陷的可视化模型:文献设计一种基于滑动滤波 与区域自动增长相结合的方法对预处理的瓷砖缺陷图像 划分为两个区域,并通过形态学操作去除杂散干扰点,提 取瓷砖裂纹特征参数给出了复杂背景干扰下的立体化瓷 砖缺陷结构检测结果<sup>[4]</sup>。然而,实际瓷砖生产环境复杂, 瓷砖背景不同对缺陷检测产生一定程度的干扰,且缺陷 在类间和类内的形状和面积大小变化不一,不同类别 缺陷之间的形状尺寸范围差异较大,比如,黑点和划痕 两类缺陷的形状和其对应的边界框尺寸范围差距较 大,同时,部分属于同一类别的缺陷中存在着形状不同 的情况,比如,划痕缺陷存在直线和弧线等形状,这导 致收集的缺陷数据图像由于缺乏多样性难以构建出较 好的特征表征空间,因此,构造一种强泛化能力的瓷砖 表面缺陷实时精准检测模型具有十分重要的理论与实 践应用价值。

近年来,深度学习在工业缺陷检测领域得到了广泛的应用。文献[5]提出了基于 YOLOv5s 的单阶段瓷砖表面缺陷检测算法,引入了注意力机制深化网络表征能力,

提高检测精度;文献[6]基于改进的两阶段网络 Faster RCNN 给出了光伏电池内部缺陷检测算法,通过引入残 差通道注意力模块突出缺陷特征并抑制背景无关信息, 提高了电池内部缺陷检测的精度和效率;文献[7]针对 PCB 表面缺陷检测效率及准确性问题提出了基于改进 YOLOv4 的 PCB 缺陷认知方法,构建快速、高精度的检测 模型。目前,深度学习的目标检测模型可分为单阶段检 测网络和两阶段检测网络,其中,面向瓷砖表面缺陷变化 不一的特点,两阶段模型能够先给出缺陷建议区域,再进 行缺陷分类给出检测结果,由此提高检测精度。瓷砖生 产过程需要对其表面缺陷进行实时精准检测,轻量级的 两阶段实时检测网络模型——ThunderNet<sup>[8]</sup>能够在低计 算量的同时具有良好的检测效果,在缺陷检测精度和速 度上达到较好的均衡。

ThunderNet 模型的骨干网络 ShuffleNet 使用深度可 分离卷积(depthwise separable convolution, DWC)<sup>[9]</sup>提取 图像由浅及深的抽象语义信息,但随着网络深度的增加, 其卷积通道和区域分离的特征提取方式会导致模型无法 充分学习到图像通道和空间之间的依赖关系,可切换空 洞卷积(switchable atrous convolution, SAC)<sup>[10]</sup>面对同一 种不同尺度的缺陷目标使用相同的卷积权值,在不同的 空洞率之间实现卷积的运算,获取特征图不同区域的感 受野切换,针对瓷砖表面缺陷大小不一的特性获取更加 有效的充分可分特征空间。另外,随着网络深度不断增 加,其提取的深层高阶抽象特征空间存在冗余信息,针对 以上问题,注意力机制[11-12]能够基于问题域在特征层突 出表征信息,在有限的神经网络层次下获取更加充分的 目标特征信息,多尺度映射将缺陷建议区域映射至不同 网络层级的输出特征图并结合通道注意力(squeeze and excitation, SE)处理,突出特定表征信息,融合深层和浅 层信息增加深层特征的位置信息,从而提高缺陷图像特 征空间的表征能力。

另外,样本数据集的规模与深度神经网络的学习效 率成正比,而瓷砖生产过程由于环境变化、缺陷特性不 一,要构建大规模、高质量的瓷砖表面缺陷数据集非常困 难,小样本条件下难以构造出充分有效的目标深层次特 征空间表征。迁移学习作为人工智能领域未来的重要 研究方向,可在不同任务之间共享特征知识,并根据新 的任务需求更迭信息空间,这与人自寻优调节具有差 异化的特征表征一致[13]。文献[14]利用迁移学习实 现蝴蝶标本至多类蝴蝶的特征迁移,构建了丰富的特 征表达空间,降低模型对样本的依赖性,取得不错的训 练效果;文献[15]建立了燃气轮机转子深度迁移故障 诊断模型,给出了有限数据下的高精度故障检测系统: 文献[16]提出一种基于迁移学习的乳腺超 CAD 算法, 将超声弹性图像中的有效特征信息迁移至基于 B 超图 像的乳腺癌 CAD 模型中,进一步提高该模型的性能。 因此,构造恰当的迁移学习模型,以具有相似特征的公 开表面缺陷样本集合构建源域模型,以瓷砖表面缺陷 样本构造目标域模型,实现深度学习模型参数的有效 迁移,继而构建高质量的瓷砖表面缺陷深度特征空间, 能够获取具有更优检测精度和泛化能力的瓷砖表面缺 陷检测模型。

针对上述问题,本文提出了一种基于深度迁移学习 和改进ThunderNet 的瓷砖表面缺陷检测方法。首先,给 出了基于模型参数的迁移学习机制,实现模型网络参数 的有效迁移;其次,构造改进的ThunderNet 网络,一方面 基于 SAC 优化 ShuffleNet 骨干网络以自适应获取不同信 息维度的特征图空间,同时,给出基于多尺度映射和 SE 的特征融合算法,突出缺陷特征信息以提高网络学习能 力;最后,开展了大量实验,验证了本文方法对于小样本 条件下的高精度实时性要求的瓷砖表面缺陷检测的可行 性与优越性。

# 1 基于深度迁移学习和改进 ThunderNet 的 瓷砖表面缺陷检测模型

为有效实现小样本条件下的瓷砖表面缺陷的高精度 实时性检测,本文构建了一种基于深度迁移学习和改进 两阶段网络 ThunderNet 的瓷砖表面缺陷检测模型,如 图1所示。模型由迁移层、训练层和检测层三层结构构 成,各层的结构和功能为:

1)迁移层

迁移层面向源域表面缺陷样本集合。首先,采用随 机翻转、缩放及色彩抖动等预处理手段建立高质量、归一 化的训练样本空间;其次,基于 SAC 优化主干网络 ShuffleNet,同时根据多尺度映射和 SE 实现具有显著注 意力权重的多维度特征融合,构建基于改进 ThunderNet 的源域表面缺陷特征空间,最终根据源域表面缺陷检测 结果给出有限源域样本下的最优模型参数。

2)训练层

训练层面向预处理后的目标域瓷砖表面缺陷样本集合。首先,基于迁移层的源域网络模型参数给出迁移策略,基于最佳迁移参数集合及改进 ThunderNet 网络构建 瓷砖表面缺陷特征空间提取模型,获取目标域多层面充 分可分特征空间,最后在分类误差交叉熵及位置绝对损 失函数约束下为检测层提供分类及位置预测的准则。

3) 检测层

检测层面向预处理后的目标域瓷砖表面缺陷测试样 本集合。基于训练层给出的特征空间提取模型获取测试 样本的同维度特征表征空间,根据训练层的分类和回归 准则标准得到测试样本的检测结果。



transfer learning and improved ThunderNet

下的充分可分特征空间构建问题,本文分别以源域表面 缺陷图像和瓷砖表面缺陷图像为对象样本,通过改进的 ThunderNet结构,获取缺陷优化可分的特征空间,网络结 构如图2所示。



Fig. 2 Improved ThunderNet network model

#### 2.1 基于模型参数的迁移学习策略

迁移学习作为一种可在不同任务共享知识的方法, 可以有效地降低目标任务数据集数量对充分可分特征空 间构建的难度<sup>[17]</sup>。然而,使用非相关相似的公开数据样 本集训练出的源域检测模型参数在迁移时忽略了目标域 缺陷形状结构特征,容易造成无效迁移甚至"负迁移"的 效果<sup>[18]</sup>,因此,本文以具有相似瑕疵特征数据集为源域 训练样本空间,以瓷砖缺陷数据为目标域训练样本空间, 分别获得改进 ThunderNet 网络的特征空间提取模型,并 给出网络参数的迁移决策算法,将改进后的 ShuffleNet 骨 干网络根据不同层的特征图维度分为 5 个阶段,迁移不 同的网络阶段参数至目标域模型,网络参数迁移策略如 图 3 所示,以缺陷图像输入 ShuffleNet 网络的初始 Stem 段作为阶段 0,开始逐次递增地迁移源域模型的不同阶 段参数,根据评价指标 mAP<sup>[19]</sup>的比较结果获得目标域模 型最大 mAP 下的迁移阶段参数集合 K,以此作为目标域 模型的预训练参数,从而充分提高目标域瓷砖表面缺陷 检测模型的特征表达能力。



Fig. 3 Diagram of network parameter transfer strategy

另外,在模型训练过程中,均采取多轮冻结解冻训练 策略,将 ShuffleNet 的 K 阶段参数在前 M 轮次训练中冻 结不进行梯度更新,在后 N 轮次解冻进行参数更新,瓷砖 表面缺陷检测模型能较好地完成知识迁移过程,在利用 源域特征知识的同时学习自身的缺陷特征,提高模型检 测性能。

### 2.2 基于 SAC 的 ShuffleNet 网络构造

如图 2 所示, ShuffleNet 是传统 ThunderNet 网络中的 骨干网络, 起到提取缺陷特征的作用。为解决 ShuffleNet 网络中 DWC 卷积通道和区域分离导致的无法有效利用 不同通道在相同空间位置上的特征信息问题,本文基于 SAC 构建 ShuffleNet 主干网络,在 ShuffleNet 最后一个阶 段的 Shuffle Block 采用 SAC 模块替换 DWC 卷积模块,实 现不同感受野的稳定切换预测机制,网络结构如图 4 所 示。SAC 模块由预处理全局上下文模块、SAC 组件、后处 理全局上下文模块串行连接构成。假设已知 ShuffleNet 最后一阶段获取的源域或目标域样本表面缺陷输入特征 图数据  $T \in R^{C \times H \times W}$ ,则由式(1)可获得不同感受野下融 合的特征图空间 T''。





$$\begin{cases} T' = F_{avg}^{pre}(T) \bigoplus T = \vartheta(f^{1\times 1}(Avgpool(T))) \bigoplus T \\ S(T') = \vartheta(f^{1\times 1}(Avgpool_{5\times 5}(T'))) \\ T'' = F_{sac}(T') = S(T') \cdot Conv(T', W^{s}, r) \\ + (1 - S(T')) \cdot Conv(T', W^{s} + \Delta W, r') \\ T''' = F_{avg}^{post}(T') = \vartheta(f^{1\times 1}(Avgpool(T''))) \bigoplus T'' \end{cases}$$

$$(1)$$

式中: T' 是源域或目标域表面缺陷具有全局信息的输入 特征图, T'' 是经由不同感受野提取融合输出的缺陷特征 数据, T'' 是最终优化后的具有全局信息的特征空间,  $F_{arg}(\cdot) \in R^{C \times H \times W}$  是全局上下文构造函数,  $F_{sac}(T') \in R^{C \times H \times W}$  是全局上下文构造函数,  $F_{sac}(T') \in R^{C \times H \times W}$  是由多个卷积块构成的可切换空洞率表征函数, ①是逐元素相加运算。这里, C = 352 是 Shuffle Block 的 输入通道数,  $H \setminus W$  分别是缺陷特征图的高和宽, 全局上 下文信息由二维自适应平均池化和卷积运算获得, 可切 换函数  $S(\cdot)$  由 5×5 平均池化层和标准 1×1 卷积层组 成,  $Conv(T', W^s, r)$  表示卷积操作,  $W^s$  是卷积权值,  $r = \{r_1, r_2\}$  表征 SAC 的空洞率,  $\Delta W$  是可训练的权重, 初始化为 0,  $\vartheta$  是 ReLU 激活函数,  $f^{1\times 1}$  是 1×1 的卷积 运算。

由此,源域或目标域表面缺陷样本图像经由基于 SAC的 ShuffleNet 骨干网络可获得不同尺度和通道数的 特征图空间。

### 2.3 基于多尺度映射和 SE 的特征融合算法

瓷砖生产过程中存在缺陷大小各异的情况,传统 ThunderNet 在建议区域检测段中利用单一维度不变的特 征空间信息进行检测,造成模型泛化能力不足的影响。 为此,本文提出了基于多尺度映射和 SE 的特征融合算 法,获取源域或目标域表面缺陷不同维度下的显著特征 图,实现同一特征层次下缺陷信息的差异化表征,如图 2 所示。

设 $k_i$ 是第i个缺陷训练样本对应 CEM 中的网络层级数,  $k_i \in [0,1]$ , 如式(2)所示。

$$\begin{cases} k_i = 1, \lfloor \log_2(\sqrt{w_i h_i} / s) \rfloor \ge 1\\ k_i = 0, \lfloor \log_2(\sqrt{w_i h_i} / s) \rfloor \le 0 \end{cases}$$
(2)

式中: w<sub>i</sub>h<sub>i</sub> 分别是缺陷的宽高, s 是映射系数, 决定了不同面积缺陷所映射的网络深度层级数。

基于  $k_i$ ,可获得缺陷训练样本集合映射后的特征图 空间  $P_k$ ,如式(3)所示。

 $P_{k} = f(k_{i}) = G[k_{i}]$  (3) 式中:  $G \in CEM$  输出的缺陷特征图序列,  $f(\cdot) \in H$  展映射函数, 表示取得特征图序列 G 中对应 $k_{i}$  的特征图, 由此实现不同大小缺陷映射至具有不同抽象层次信息的网络阶段, 获得训练样本集合映射后的特征图空间  $P_{k}$ 。

进一步的,为突出表征训练样本表面缺陷特征图不 同通道间的相关性,本文在融合算法中引入 SE 模块<sup>[20]</sup>, 以自适应重新校准通道方向的特征响应,SE 模块结构如 图 5 所示。

设输入的源域或目标域样本表面缺陷特征图  $U' \in \mathbb{R}^{C' \times H' \times W'}$ ,则由式(4)可获得具有注意力权重的表面缺陷输出特征图空间Y''。



图 5 SE 模块结构图 Fig. 5 SE module structure diagram

-

$$\begin{cases} Y = F_{sq}(U') = \frac{1}{H' \times W'} \sum_{i=1}^{H'} \sum_{i=1}^{W'} u'_{c'}(i,j) \\ Y' = F_{ex}(Y, W^{se}, r^{se}) = \sigma(W_2^{e}\delta(W_1^{s}Y)) \\ Y'' = F_{scale}(Y', U') = Y' \otimes U' \end{cases}$$
(4)

式中: *Y* 是源域或目标域表面缺陷特征在通道维度上所响应的全局分布, *Y'* 是表面缺陷在通道维度上的加权特 征图空间, *Y''* 是最终输出的具有注意力信息的重构特征 图空间, *F<sub>sq</sub>*(*U'*)  $\in \mathbb{R}^{C\times 1\times 1}$  是1 维通道注意力特征描述 函数, *F<sub>sq</sub>*(*U'*)  $\in \mathbb{R}^{C\times 1\times 1}$  是在压缩率 *r*<sup>\*e</sup> 下的1 维 特征重构函数, *F<sub>scde</sub>*(*Y'*, *U'*) 是通道维度逐元素相乘函 数。其中, *C'* 是输入 SE 模块的特征图通道数, *H'*、*W'* 是 特征图的高和宽, *W*<sup>\*e</sup> = {*W*<sub>1</sub><sup>\*</sup>, *W*<sub>2</sub><sup>\*</sup>} 是特征描述函数中的 参数集合, *W*<sub>1</sub><sup>\*</sup>  $\in \mathbb{R}^{\frac{C}{r}\times C}$  是压缩卷积层参数, *W*<sub>2</sub><sup>e'</sup>  $\in \mathbb{R}^{C\times \frac{C}{r}\times C}$ 是还原卷积层参数, *r*<sup>\*e</sup> 是通道压缩率,  $\sigma$  表示 Sigmoid 激 活函数,  $\delta$  表示 ReLU 激活函数,  $\otimes$  表示通道维度上对应 元素相乘。

由此,基于训练样本映射后的缺陷特征空间 P<sub>k</sub>和 SE 模块,本文给出了一种多尺度特征融合算法,将经过 SE 模块重标定后的特征图与邻层特征图相加,实现不同尺 度下的特征空间融合表征,融合算法如式(5)所示。

 $F = f(SE_{t}(P_{t}) \oplus P_{1-t})$  (5) 式中:  $P_{t} \in \mathbb{R}^{C^{\times}H^{*}\times W^{*}}$ ,其中  $C^{"} = 216$ , $H^{"}$ 、 $W^{"}$ 均是7,  $SE_{t}$ 是 不同尺度下的 SE 模块,  $t \in \{0,1\}$ ,  $\oplus$  表示特征图逐元 素相加, f是隐含全连接层网络。由此,对 CEM 输出的源 域或目标域表面缺陷特征图集合,由多尺度映射和 SE 的 特征融合算法处理后可得到缺陷样本图像信息的优化表 征  $F = [F_{0}, \dots, F_{i}, \dots, F_{n}, O_{n}]$ ,其中, $F_{i}$ 为第 i 个缺陷训 练样本构建具有显著表征的优化特征向量,  $O_{n}$ 为缺陷样 本真实决策属性向量,即源域或目标域表面缺陷类别及 位置标签。

最后,基于分类交叉熵损失和 Smooth-L1 损失定义 改进两阶段网络的损失函数,如式(6)所示。

ハ <math> au:  $o_{(x,y,w,h)}$  乃 畎 阳 时 顶 测 位 直,  $b^-$  为 Ground-Truth 真 实 框, 即 缺 陷 位 置 标 注 值,  $c^*$  为 缺 陷 真 实 类 别 标 签, 如 果

 $c^* = 0$ 表示为背景,  $L_{cls}(Y^l, Y_{c^*l}) = -\ln_{cls}(Y^l + Y_{c^*l})$ 表示 交叉熵损失函数,  $L_{reg}$ 表示 Smooth-L1 边框回归损失函 数。由此,据源域或目标域训练样本集合构建的优化特 征向量和真实缺陷标签可获得模型损失值,计算梯度反 向传播实现模型网络参数的迭代更新,获取近似最优解 下的模型参数值,继而给出缺陷检测结果。

2.4 基于深度迁移学习和改进 ThunderNet 的瓷砖表面 缺陷检测算法

为实现瓷砖表面缺陷的高精度实时性检测,由上述 迁移机制、基于 SAC 的 ShuffleNet 网络、多尺度映射和 SE 的特征融合算法,本文给出了基于深度迁移学习和改进 ThunderNet 的瓷砖表面缺陷检测算法,如算法1所示。

```
Algorithm 1 基于深度迁移学习和改进 ThunderNet 的瓷砖
表面缺陷检测算法
Input: 输入铝材缺陷训练样本集 U<sub>s</sub> 和测试样本集 Q<sub>s</sub>, 瓷
```

- 砖表面缺陷训练样本集  $V_t$  和测试样本集  $S_t$ ,ShuffleNet 阶段参数为  $S = \{s_1, s_2, ..., s_M\}$ ,SAC 模块参数  $r_1, r_2 \in$ 1,2,3},SE 模块参数  $r^{se} \in \{6, 12, 24, 36\}$ , 设 $r_1 = 1, r_2 =$  $1, r^{se} = 6, K = \{s_0\}, Q = \emptyset$
- Output: 瓷砖表面缺陷类别 CLA<sub>t</sub>, 位置回归坐标 REG<sub>t</sub>, 平 均检测精度 mAP
  - 1: for  $m = 1 \rightarrow M$  do
  - 获取迁移不同阶段参数 {s<sub>0</sub>,...,s<sub>m</sub>} 模型 model<sub>m</sub>, 训练 并评估模型精度 mAP<sub>m</sub>
- 3: if  $mAP_m > mAP_{m-1}$  then
- 4:  $K \Leftarrow K \cup Q \cup \{s_m\}$
- 5: else
- $6: \qquad Q \Leftarrow Q \cup \{s_m\}$
- 7: end if
- 8: end for; Output K
- 9: 获取在测试集下最大 mAP 模型对应的 SAC 参数 r<sub>1</sub>, r<sub>2</sub>
- 10: 获取在测试集下最大 mAP 模型对应的 SE 参数 r<sup>se</sup>
- 11: 获取测试集的最优特征表达空间 Pk
- 12: 基于分类和回归准则获取最优模型参数下的 GLA<sub>t</sub>, REG<sub>t</sub>, mAP
- 13: return  $GLA_t, REG_t, mAP$

该算法在传统的模型训练中加入了迁移学习机制, 以模型的平均检测精度 mAP 评价指标评估当前迁移参 数集合 K 的迁移效果,并获得 SAC 模块中最佳参数值  $r_1,r_2$  与 SE 模块的最佳压缩率  $r^*$ ,实现了检测系统中输 入缺陷图像集的优化特征空间  $P_k$  的建立和最终缺陷分 类和位置定位结果的输出。

## 3 实验与结果分析

为了验证本文算法的可行性和有效性,本文进行了 消融对比实验。源域样本数据分别取自 PaddlePaddle 公 开铝材表面缺陷数据集、东北大学热轧带钢表面缺陷数 据集<sup>[21]</sup>(NEU-DET dataset),目标域瓷砖缺陷数据来源于 实际生产线采集,采集设备为工业线阵彩色 CCD 相机 HIKROBOT MV-CL086-91C-C,得到瓷砖数据图像共有 1975 张,铝材数据图像共 2254 张,热轧带钢图像共 1800 张,瓷砖图片尺寸为 512×512,铝材图片尺寸为 2048×1000,热轧带钢图片尺寸为 200×200,根据缺陷的

形状和大小将缺陷分为划痕、黑点、边裂、面部磕碰、脏污 以及断角6种类型,使用 LabelImg 软件标注后构建瓷砖 缺陷目标域及源域样本集,部分缺陷图像如图6所示。



图 6 部分缺陷图像样本

Fig. 6 Partial defect image samples

文中进行的对比和消融实验均为从样本集采用5折 交叉验证方法以80%:10%:10%的比例,分别构造训 练集、验证集和测试集,以保证实验样本的随机性和实验 数据的可靠性。本文深度学习模型为轻量级两阶段检测 网络 ThunderNet, 网络训练预加载 coco 数据集预训练权 重, 深度学习框架为 Pytorch1.10.0、CUDA11.1、 CUDNN8.0.5, 训练周期数 Epoch = 30, 瓷砖缺陷训练集 批处理大小 Batch\_size = 16, 热轧带钢缺陷训练集批处理 大小 Batch\_size=16,铝材缺陷训练集批处理大小 Batch size=8,分类损失函数为 CrossEntropyLoss,损失权重 loss\_ weight=1.0,位置回归损失函数为 Smooth-L1Loss,损失权 重 loss\_weight = 1.0, 网络优化函数为 SGD, 学习率 learning\_rate = 0.0025,动量值 momentum = 0.9,权重衰减 因子 weight\_decay=0.0001,SAC 模块的两个卷积空洞率 r1、r2 均从固定集合{1,2,3}随机选取给出,以获取最优 的面向瓷砖表面缺陷的空洞率参数组合,SE 模块的通道 压缩超参数 r<sup>se</sup> 从预设定集合 {6,12,24,36} 中寻优选取, 以增强搜索适宜通道压缩率的可能性,映射算法的映射 系数为160,迁移策略中模型的训练轮次参数 M=20,N= 10。检测结果均基于综合性指标平均召回率(average recall, AR)、平均检测精度(mean average precision, mAP)、平均推理时间指标(frames per second, FPS)和模 型参数量(parameters, Params)给出评估,其中,检测交并

比得分阈值为 0.5, AR 指标为各类别缺陷检测召回率的 均值, 其值的大小代表了模型漏检情况的好坏, mAP 指 标为各类别缺陷检测精度的均值, 其值表示模型对所有 类别缺陷的检测准确度, FPS 指标为模型在测试样本集 上推理单张缺陷图像所需要的平均时间, 反映了模型的 检测速度, Params 指标为模型中需要学习的参数数量, 衡 量了模型的空间复杂度和模型大小, 另外, 文献[5] 给出 了各项指标的详细计算方式。所有实验均在 CPU intel-Xeon, 16 G 内存, 显卡 GPUTesla T4 环境下运行。

为了验证源域样本与目标域样本缺陷相似度对迁移 效果的影响,图 7 给出了 3 种源域数据检测模型参数迁 移后的瓷砖表面缺陷检测模型的性能对比曲线。由图可 以看出,以铝材、热轧带钢缺陷为源域数据的迁移模型检 测效果均有明显提升,其中铝材源域模型对应的目标域 缺陷检测效果最佳,而迁移 COCO 源域模型参数的缺陷 检测效果一般,这是由于 COCO 作为一种通用数据集,其 图片特征具有一般性,与瓷砖表面缺陷特性相关性较低; 而铝材数据集中的各种缺陷与瓷砖缺陷形状结构相似度 高,热轧带钢数据集中仅部分缺陷相似,因此,选取铝材 缺陷样本作为源域模型的输入,实现源域特征知识到目 标域的正向有效迁移,提升目标域模型的性能和学习 效率。

为探索 SAC 模块的最佳的空洞率参数组合,图 8 给









出了训练过程中不同空洞率组合下验证集的平均检测精 度变化曲线。从图中可以看出,在 $r_1 = r_2$ 时,随着空洞率 逐渐增大,检测精度并没有明显提升,在 $r_1 \neq r_2$ 时,空洞 率较大的参数组合 ( $r_1 = 2, r_2 = 3$ )模型性能要低于空洞 率较小组合 ( $r_1 = 1, r_2 = 2$ )的检测模型。这是由于瓷砖 表面缺陷具有不同形状大小的结构特点,空洞率参数较 大会造成卷积稀疏性地提取特征,导致较小目标特征的 缺失,相同较小空洞率参数组合无法实现感受野的切换 机制,因此,选定 $r_1 = 1, r_2 = 2$ 作为本文 SAC 模块的最优 参数组合。

为了验证本文所提特征融合算法的有效性,图9给 出了有无本文特征融合算法与使用空洞空间金字塔池化 (atrous spatial pyramid pooling, ASPP)<sup>[22]</sup>特征融合算法 的模型在训练过程中的精度变化曲线,从图中可以看出, 结合特征融合算法的模型检测效果均比原始模型要好, 其中,融合本文特征融合算法的模型精度略高于基于 ASPP的模型检测精度,同时,本文分别计算了使用两种 算法的模型参数量,相比原模型参数量(14.82 M),基于 多尺度映射和通道注意力的融合算法模型参数量为 15.28 M,仅增加了3%参数量,而基于ASPP算法的模型 参数量为17.11 M,增加了15%的参数量,这说明基于多 尺度映射和SE的特征融合算法模型在瓷砖表面缺陷检 测效果和模型大小上更具有优势。



图 10 给出了 SE 模块不同通道压缩率下模型以及添 加注 意 力 模 块 (convolutional block attention module, CBAM)<sup>[23]</sup>模型的平均检测精度变化图,由图可以看出, 使用 CBAM 模型的检测精度高于部分 SE 压缩率下的模 型,低于最佳 SE 压缩率下模型精度。其中,在添加了 SE 模块的模型中, r\*\* = 36 时模型检测性能不佳,随着 r\*\* 的 减小,瓷砖表面缺陷检测性能并不总是呈现单调递增趋 势,当 r\*\* = 6 时,精度出现下降,模型出现过拟合现象。 这一结果表明,压缩率减小的同时 SE 模块中的隐藏层节 点数随之增加,过多的节点数使得在通道维度的特征重 标定出现冗余信息,而过少的隐层节点难以充分学习到 不同通道间的相互依赖关系,突出特定特征信息抑制无 用特征能力不足。本次实验中在压缩率 r\*\* = 24 时,基于 多尺度映射和 SE 的特征融合算法的瓷砖表面缺陷检测 模型性能较好。

为了验证迁移算法的可行性,图 11 所示为 30 轮次 过程中不同迁移集合 K 的模型和原始模型在相同的验证 集上 mAP 和损失值 Loss 的变化对比曲线。从图 11 可以 看出,基于相同的瓷砖表面缺陷样本集和评价指标下,迁 移参数后的模型( $K = \{s_0\}, K = \{s_0, s_1\}, K = \{s_0, s_1, s_2\}$ )的 初始损失值均比未迁移模型( $K = \{\emptyset\}$ )要低,网络收敛稳 定,损失值下降速度快,在收敛阶段的损失值均比迁移前 低。另外,迁移参数后的模型在训练初期便有很好的检 测效果,网络收敛阶段精度均比迁移前有提升,证明了迁 移方法的可行性,随着迁移参数的增加,模型性能相对降 低,由此可知最佳的迁移参数集合  $K = \{s_0\}, 其中 s_0$ 为 ShuffleNet 的 Stem 阶段的网络参数。





Fig. 10 Performance curves of SE models under different r<sup>se</sup>



为了进一步验证迁移学习方法在小样本条件下的可 行性,能够降低模型对数据量的依赖,本文基于改进两阶 段方法分别对不同数量瓷砖图像训练样本下的迁移模型 与未迁移模型训练并评估性能,其中,迁移模型的迁移集 合 K= {s<sub>0</sub>},对比结果如表1所示。

表 1 不同训练样本下的迁移与未迁移模型指标对比值 Table 1 Comparison of transferred and untransferred model metrics under different training samples

训练样本	迁移模型		未迁移模型		
数量	AR/%	mAP/%	AR/%	mAP/%	
300	62.19	53.93	53.24	41.75	
600	82.18	73.37	80.06	64.35	
900	89.64	84.91	87.08	81.74	
1200	91.36	85.13	89.18	83.45	

结果表明,与未迁移源域预训练权重模型相比,使用 迁移学习方法的模型在小样本条件下仍然保持着不错的 精度和召回率,由此可见,基于模型参数迁移学习方法可 以有效降低数据量对模型收敛情况的影响,并提高模型 泛化能力,对于解决样本数量不足的任务有着重要的实 践价值。

此外,基于相同的瓷砖缺陷测试图像样本,本文比较 了本文方法与单阶段检测算法 YOLOv7<sup>[24]</sup>、 RetinaNet<sup>[25]</sup>,两阶段检测算法 Libra\_RCNN<sup>[26]</sup>及 Transformer<sup>[27]</sup>等主流目标检测方法的评价结果,以及对 比了分别使用 SAC 和基于多尺度映射、SE 的特征融合算 法的模型在测试集上的评估值,并给出了各模型在训练 过程中的检测精度对比曲线,如图 12 所示,其中,所有方 法的相关超参数均使用最佳参数组合。



Fig. 12 Comparison of detection performance of each model

#### 表 2 不同算法的评价指标对比

 Table 2
 Comparison of evaluation value

of different methods

方法	AR/%	mAP/%	FPS ms∕img	Params/M
本文方法				
(ThunderNet+SAC+	93.69	87.22	61.6	22.30
特征融合+Transfer)				
ThunderNet+SAC	91.21	83.43	60. 9	21.85
ThunderNet+特征融合	90.65	84.08	53.9	15.28
ThunderNet+Transfer	90.55	81.78	53.7	14.84
ThunderNet	89.53	77.92	53.2	14.82
YOLOv7	90.23	74.54	61.7	36.31
RetinaNet	87.64	64.37	64.7	36.43
Transformer	90. 23	78.45	60.1	58.35
Libra_RCNN	92.53	81.37	68.2	41.63

由表2可知,本文提出的基于SAC、多尺度映射和 SE特征融合算法的检测模型比其他方法有更优的性能 表现,其中,采用SAC和特征融合方法的模型分别比原 模型检测精度提升了5.51%、6.16%,本文方法的模型平 均检测精度达到了87.22%,比原模型提升了9.30%,均 高于其他主流检测模型,在模型的参数量和推理速度上 也有不错的优势,检测速度达到了61.6 ms/img,满足瓷 砖表面缺陷的实时精准检测要求,同时,从图 12 可以直 观地看出本文方法相比其他算法在检测精度方面的优 势。由此,本文提出的改进 ThunderNet 检测方法在瓷砖 表面缺陷检测性能上有较大的提升,在检测精度和实时 性上获得了较好的检测效果,部分缺陷检测结果如图 13 所示。



图 13 部分瓷砖表面缺陷样本检测结果图



## 4 结 论

为了克服实际场景下难以获取到多样性、高质量的 瓷砖表面缺陷图像样本集的问题,小样本条件下网络优 化困难,测试样本特征空间面向多变的缺陷可分信息不 足,本文提出了一种改进的两阶段 ThunderNet 检测模型, 采用 SAC 提高网络对不同尺度检测对象的学习适应性, 并基于多尺度映射和 SE 的特征融合方法构建多层次差 异化的特征知识空间,更有利于后续分类和位置预测。 另外,迁移学习方法的运用在较大程度上降低网络对数 据量的依赖,有效增强目标域特征空间的泛化能力,加速 网络收敛的同时提高模型检测精度。本文提出的基于深 度迁移学习和改进 ThunderNet 的瓷砖表面缺陷检测模型 能够有效的对瓷砖缺陷进行检测,具有较高的参考价值, 后续对复杂花色背景瓷砖的表面缺陷检测将是未来的研 究重点。

#### 参考文献

- ZHAO Z. Review of non-destructive testing methods for defect detection of ceramics[J]. Ceramics International, 2021, 47(4): 4389-4397.
- [2] ZHANG H, PENG L, LEI G. Saliency detection for surface defects of ceramic tile [J]. Ceramics International, 2022, 48(21): 32113-32124.
- [3] SIOMA A. Automated control of surface defects on ceramic tiles using 3D image analysis [J]. Materials, 2020, 13(5): 1250.
- [4] LI X, ZENG S, ZHENG S, et al. Surface crack detection of ceramic tile based on sliding filter and automatic region growth [J]. Laser Optoelectron. Prog, 2019, 56: 211003.
- [5] WAN G, FANG H, WANG D, et al. Ceramic tile surface defect detection based on deep learning [J].

Ceramics International, 2022, 48(8): 11085-11093.

[6] 伊欣同, 单亚峰. 基于改进 Faster R-CNN 的光伏电池 内部缺陷检测 [J]. 电子测量与仪器学报, 2021, 35(1):40-47.

YI X T, SAN Y F. Internal defect detection of photovoltaic cells based on improved Faster RCNN[J]. Journal of Electronic Measurement and Instrumentation, 2021,35(1):40-47.

- [7] 伍济钢,成远,邵俊,等. 基于改进 YOLOv4 算法的 PCB 缺陷检测研究 [J]. 仪器仪表学报, 2021, 42(10):171-178.
  WU J G, CHENG Y, SHAO J, et al. PCB defect detection based on improved YOLOv4 algorithm [J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 171-178.
- Qin Z, LI Z, ZHANG Z, et al. ThunderNet: Towards real-time generic object detection on mobile devices [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6718-6727.
- [9] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251-1258.
- [10] XUE R, XIANG W, DENG Y. Improved faster R-CNN based on CSP-DPN [J]. Procedia Computer Science, 2022, 199: 1490-1497.
- [11] CHEN K, AN J, FANG Y, et al. Research on solid waste plastic bottle cognitive based on YOLOv5s and deep stochastic configuration network [J]. 2022 7th International Conference on Automation, Control and Robotics Engineering (CACRE), 2022: 275-280.
- [12] 韩岩江,王伟,王峰萍.融合坐标注意力和 BiFPN 的 YOLOv5s 交通标志检测方法[J].国外电子测量技 术,2022,41(11):170-179.
   HAN Y J, WANG W, WANG F P. YOLOv5s traffic sign

detection method based on coordinate attention and BiFPN[J]. Foreign Electronic Measurement Technology, 2022, 41(11): 170-179.

 [13] 李帷韬,韩慧慧,焦点,等.基于深度迁移学习的大 雾等级智能认知方法研究[J].电子测量与仪器学 报,2020,34(2):88-96.

> LI W T, HAN H H, JIAO D, et al. Research on foggy hierarchical intelligent cognition method based on deep transfer learning[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 88-96.

[14] 李策,张栋,杜少毅,等.一种迁移学习和可变形卷 积深度学习的蝴蝶检测算法[J].自动化学报,2019, 45(9):1772-1782.

> LI C, ZHANG D, DU SH Y, et al. A butterfly detection algorithm for transfer learning and deformable convolution deep learning [J]. Journal of Automatica Sinica, 2019, 45(9): 1772-1782.

[15] 唐竞鹏,王红军,钟建琳,等.基于 WDCNN-SVM 深 度迁移学习的燃气轮机转子故障诊断方法[J].电子 测量与仪器学报,2021,35(11):115-123.

TANG J P, WANG H J, ZHONG J L, et al. Fault diagnosis method of gas turbine rotor based on WDCNN-SVM deep transfer learning [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (11): 115-123.

[16] 贡荣麟,施俊,周玮珺,等.面向乳腺超声计算机辅助诊断的两阶段深度迁移学习[J].中国图象图形学报,2022,27(3):898-910.

GONG R L, SHI J, ZHOU W J, et al. Two-stage deep transfer learning for computer-aided diagnosis of breast ultrasound [J]. Journal of Image and Graphics, 2022, 27(3): 898-910.

- [17] CHOWDHURY D, DAS A, DEY A, et al. CoviDetector: A transfer learning-based semi supervised approach to detect Covid-19 using CXR images [J]. BenchCouncil Transactions on Benchmarks, Standards and Evaluations, 2023, 3(2): 100119.
- [18] 郝柏桥,范玉刚,宋执环.基于深度迁移学习的脉冲 涡流热成像裂纹缺陷检测[J].光学学报,2023, 43(4):146-154.

HAO B Q, FAN Y G, SONG ZH H. Crack defect detection based on deep transfer learning for pulsed vortex thermal imaging[J]. Acta Optica Sinica, 2023, 43(4): 146-154.

- [19] YAN H, PENG X, CHEN C, et al. YOLOx model-based object detection for microalgal bioprocess [J]. Algal Research, 2023, 74: 103178.
- [20] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.

- [21] HE Y, SONG K, MENG Q, 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.
- [22] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40 (4): 834-848.
- [23] WOO S, PARK J, LEE J Y, et al. Cham: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV). 2018; 3-19.
- [24] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-theart for real-time object detectors [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [25] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [ C ]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [26] PANG J, CHEN K, SHI J, et al. Libra R-CNN: Towards balanced learning for object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 821-830.
- [27] SONG H, SUN D, CHUN S, et al. Vidt: An efficient and effective fully transformer-based object detector[J]. arXiv preprint arXiv:2110.03921, 2021.

#### 作者简介



**陈克琼**,分别 2008 年、2011 年和 2017 年于合肥工业大学获得学士学位、硕士学位 和博士学位,现为合肥大学讲师,主要研究 方向为模式识别与智能系统、机器视觉。 E-mail: chenkq@ hfuu. edu. cn

Chen Keqiong received her B. Sc.

degree, M. Sc. degree and Ph. D. degree from Hefei University of Technology in 2008, 2011 and 2017 respectively. Now she is a lecturer in Hefei University. Her main research interests include pattern recognition and intelligent systems, and machine vision.



**卓士虎**(通信作者),2020年于铜陵学院 获得学士学位,现为合肥大学硕士研究生,主 要研究方向为深度学习和计算机视觉。

E-mail: shihu\_zhuo@163.com

Zhuo Shihu (Corresponding author)

received his B. Sc. degree from Tongling University in 2020. Now he is a M. Sc. candidate in Hefei University. His main research interests include deep learning and computer vision.