

文章编号 1004-924X(2024)10-1622-16

并行特征提取和渐进特征融合的计算机 主板装配缺陷检测

陈俊英, 李朝阳*, 黄汉涛, 董戊泽

(西安建筑科技大学 信息与控制工程学院, 陕西 西安 710055)

摘要:针对计算机主板装配缺陷检测中的元器件位置分布复杂、缺陷目标不显著及多尺度等问题,本文提出了一种并行特征提取和互交叉渐进特征融合的端到端的缺陷检测算法。首先,结合部分卷积和视觉 Transformer 提出了一种并行残差特征提取网络,利用部分卷积的低计算复杂度的优势提取局部特征,同时利用视觉 Transformer 的长距离建模能力扩大模型的感受野,增强网络的特征提取能力。其次,引入注意力机制和特征渐进融合机制,提出了一种多尺度注意力互交叉的渐进特征融合网络,增强检测模型的特征融合能力。在公开数据集上的实验结果表明,该算法的平均精度均值 (mAP) 达到了 94.63%,相较于基线模型 YOLOv5 提升了 4.62%,并优于其他几种先进模型,检测速度达到了 25 FPS。实现了较好的检测精度与速度的平衡,为实际工业环境下计算机主板表面装配缺陷检测自动化和智能化的实现提供了一种快速、有效的方法。

关键词:计算机主板装配缺陷检测;并行特征提取;渐进特征融合;视觉 Transformer;部分卷积

中图分类号:TP394.1;TH691.9 **文献标识码:**A **doi:**10.37188/OPE.20243210.1622

Computer motherboard assembly defect detection using parallel feature extraction and progressive feature fusion

CHEN Junying, LI Zhaoyang*, HUANG Hantao, DONG Xuze

(School of Information and Control Engineering, Xi'an University of Architecture and
Technology, Xi'an 710055, China)

* Corresponding author, E-mail: nicholas@xauat.edu.cn

Abstract: In view of the complex distribution of component positions, lack of prominent defect targets, and multi-scale issues in the detection of defects in computer motherboard assembly, this paper proposed an end-to-end defect detection algorithm based on parallel feature extraction and cross-attention progressive feature fusion. Firstly, a parallel residual feature extraction network was proposed by combining partial convolution and visual Transformer. The low computational complexity of partial convolution was utilized to extract local features, while the long-distance modeling ability of visual Transformer was utilized to expand the receptive field of the model and enhance the feature extraction ability of the network. Secondly, the cross-attention mechanism was introduced to progressively fuse multi-scale features, and a multi-scale cross-attention progressive feature fusion network was constructed to enhance the feature fusion ability of the detection model. The experimental results on the public dataset show that the mean average

收稿日期:2023-12-08;修订日期:2024-03-05.

基金项目:国家自然科学基金项目(No. 62103316);陕西省自然科学基金基础研究计划项目(No. 2023-JC-YB-562)

accuracy (mAP) of the algorithm reaches 94.63%, which is 4.62% higher than the baseline model YOLOv5 and is superior to several other advanced models. The detection speed reaches 25 FPS, achieving a good balance between detection accuracy and speed. It provides a fast and effective method for the automation and intelligence of surface assembly defect detection on computer motherboards in the actual industrial environment.

Key words: detection of defects in computer motherboard assembly; parallel feature extraction; progressive feature fusion; visual transformer; partial convolution

1 引言

计算机主板是计算机的核心组成部件。计算机在生产过程中需要经过主板装配、测试、包装等多道加工工序。在主板装配阶段容易出现固定螺丝的漏装、错装和松动等问题,主板装配质量的好坏直接影响计算机后续功能测试的合格率。目前,计算机主板的装配质量检测任务主要依靠人工目视法来完成^[1],易造成检测过程效率低、良品率不稳定等问题。因此,研究计算机主板装配缺陷的自动化检测方法,提高计算机主板装配质量的检测准确率和效率就变得尤为重要。

机器学习作为人工智能的重要分支,在此基础上进一步发展起来的深度学习与机器视觉在工业生产中发挥着重要的作用。目前,基于深度学习的相关视觉缺陷检测方法发展迅猛,国内外相关学者尝试把机器视觉和深度学习算法应用于印制电路板(PCB)缺陷检测^[2]、太阳能电池缺陷检测^[3]、焊缝^[4]和晶圆^[5]缺陷检测等方面,推动了深度学习缺陷检测方法的落地应用。根据工业应用场景中缺陷的特征与检测的速度要求进行设计,深度学习可取得比传统视觉检测方法更好的检测性能。Tu等人^[6]针对计算机主板表面装配质量检测提出一种实时缺陷检测算法 QD-YOLO,解决装配质量检测存在的效率低、容易漏检、误检等问题,验证了深度学习算法在计算机主板表面装配质量缺陷检测任务中的可行性。陈仁祥等人^[7]针对工业环境中噪声干扰导致的 PCB 缺陷检测困难问题,提出基于多注意力 Faster-RCNN 的印刷电路板缺陷检测方法,在 PCB 数据集上取得了良好的性能。Luo J 等人^[8]针对不同缺陷之间具有相似的外观提出了解耦两阶段目标检测框架,在 PCB 缺陷检测任务上取得较高的检测速度和精度。综上所述,机器视觉

和深度学习的结合已经成为解决工业环境下缺陷检测问题的主流方法。

但对于计算机主板,其构成元器件种类多、位置分布复杂,具有缺陷目标不显著性、不同缺陷之间的高相似性和尺度差异显著等问题。同时,实际工业生产环境下的检测缺陷样本相对稀缺,这些都使得计算机主板的装配缺陷检测成为工业缺陷检测领域中的一项复杂难题。针对上述问题本文提出了一种基于改进 YOLOv5 的端到端计算机主板表面装配缺陷检测方法。首先,结合视觉 Transformer 和部分卷积提出并行残差特征提取网络。融合视觉 Transformer 自注意力机制的长距离建模能力,扩大模型的感受野,提升模型对于计算机主板特征的提取能力,解决计算机主板装配缺陷检测中元器件种类繁多、位置分布复杂、缺陷目标不显著等问题。其次,结合注意力机制和渐进特征融合网络,提出基于多尺度互交叉注意力加权的渐进特征融合网络,增强特征图融合的表达性,解决计算机主板缺陷目标多尺度性等问题。最后在公开数据集上对提出的方法进行验证。

2 相关工作

2.1 YOLOv5

ADIBHATLA 等人^[9]将 YOLOv5 算法用于 PCB 的缺陷检测,显著减少了 PCB 缺陷检测的人力、物力需求。YOLOv5 的网络结构主要分为主干特征提取网络(Backbone)、特征融合网络(Neck)和输出预测网络(Head)三个部分。主干特征提取网络包括基础卷积(CBS)模块、空间金字塔池化(SPP)结构和切片结构(Focus)。Neck 部分采用路径聚合网络(PANet)结构,实现多尺度特征融合。Head 部分通过非极大值抑制算法输出预测类别与目标位置的预测框。本文选取 YOLOv5 模

型作为基础框架,并针对其 Backbone 和 Neck 部分进行优化改进,旨在提高计算机主板装配缺陷检测的精度,以满足实际工作环境中的检测需求。

2.2 视觉 Transformer

近年来,视觉 Transformer (Vision Transformer, ViT)^[10] 凭借其卓越的全局特征建模能力在计算机视觉领域取得显著成就。ViT 采用一种新的范式,通过纯 Transformer 结构替代传统卷积神经网络的卷积池化结构,在超大规模数据集上取得了超越卷积神经网络的效果。ViT 的核心是自注意力机制,自注意力机制通过将输入序列线性变换映射为查询(Query)、键(Key)、值(Value)等向量,计算查询向量与键值向量之间的相似度权重,对相似度权重进行 Softmax 运算得到最终注意力权重,对值向量矩阵进行点积加权,得到最终的输出向量,这种自注意力机制赋予了 ViT 强大的长距离建模能力。因此,本文将自注意力机制融入特征提取网络与特征融合网络中,充分利用其长距离建模能力。

3 本文方法

3.1 计算机主板缺陷检测网络架构

本文提出了一个基于 YOLOv5 的计算机主板装配缺陷检测算法,该算法通过并行特征提取和渐进特征融合的方式,对原有的 YOLOv5 算法进行了改进。改进后的算法整体网络架构如图 1 所示,其中主干网络(Backbone)被替换为本文所提出的视觉 Transformer 和部分卷积相结合的并行残差特征提取网络 VTNet。同时,结合渐进特征融合网络和自注意力机制,本文还提出了多尺度互交叉渐进特征融合网络,以增强网络的多尺度特征融合能力。在预测子网络(head)部分,该算法使用三个不同尺度的特征图来预测不同尺度的缺陷目标,实现计算机主板表面不同形状和尺寸的缺陷目标检测。改进算法旨在有效解决主板缺陷检测任务中缺陷类型相似度高、缺陷特征显著性低以及缺陷目标的多尺度问题,提高计算机主板表面装配缺陷的检测精度。




图 1 计算机主板装配缺陷检测网络结构图

Fig. 1 Network architecture for defect detection in computer motherboard assembly

3.2 视觉 Transformer 和部分卷积相结合的并行残差特征提取网络

本文所采用的基线模型 YOLOv5 采用了

CSPDarkNet^[11] 主干网络,大量研究表明 CSPDarkNet 网络在缺陷检测领域的可行性^[12-14]。然而,针对计算机主板表面装配缺陷检测,由于缺

陷位置分布复杂且相似度高, CSPDarkNet 网络的感受野相对较小, 特征提取能力较弱无法充分提取具有表达细节特征的信息, 从而影响了最终的缺陷检测精度。

因此, 本文提出了一种新的特征提取网络 VTNet, 结合了视觉 Transformer 的长距离特征建模能力与部分卷积 (PConv)^[15] 的局部建模能力。其网络结构如图 2 所示, 其中左图为并行特征提取网络的整体架构, 右图为基础块 VT-

FastNetBlock 的网络结构。VT-FastNetBlock 是由 FasterNet Block 与基于视觉 Transformer 的残差特征提取路径组成的并行网络结构。图中 $H \times W$ 表示输入图像的高和宽, 所提出的特征提取网络 VTNet 主要由 4 个 Stage 组成, 每个 Stage 都由 VT-FasterNetBlock 并行特征提取网络进行特征提取, 采用 Stage2, Stage3 和 Stage4 的输出特征图作为后续参与特征融合的多尺度特征图。




图 2 特征提取网络 VTNet 的网络结构

Fig. 2 Network structure of VTNet feature extraction network

VT-FasterNetBlock 的网络结构图如下图 3 所示, 对输入图像 $x \in \mathbf{R}^{H \times W \times 3}$ 来说, 首先经过嵌入层将其转换为特征图 $f \in \mathbf{R}^{H \times W \times C}$, 嵌入层为一个步长为 4 的常规 4×4 卷积, 在后续每个阶段之前, 嵌入一个步长为 2 的 2×2 的常规卷积作为合并层, 用于特征图的空间降采样与通道扩展。考虑实际工业环境下对模型检测的实时性要求, 在每个 Stage 内, 引入部分卷积与常规卷积构成主要的局部特征提取操作。所提出的方法在部分卷积的特征提取路径基础上引入由视觉 Transformer 构成的残差特征提取模块。对于图像来说, 高层的语义概念是稀疏的, 不同的语义概念只会出现在图像的小部分区域内^[16]。因此本文在构建基于视觉 Transformer 的残差特征提取路径时首先对输入特征图进行令牌 (Token) 化, 实现对高级语义概念的建模, 即将学习的内容从整张图像的特征信息变换为语义 Tokens。令牌化 (Tokenizer) 的具体操作流程为对于每个阶段的

输入特征图 $z \in \mathbf{R}^{H \times W \times C_i}$, C_i 指每个阶段输入特征图的通道数, 通过一个线性层映射得到 L 组语义向量 $X \in \mathbf{R}^{C \times L}$, 对向量 $X \in \mathbf{R}^{C \times L}$ 进行 Softmax 操作, 将每个像素 $x_p \in \mathbf{R}^C$ 都映射到 L 组语义向量, 得到权重张量 $A \in \mathbf{R}^{H \times W \times L}$ 。再对其转置与输入特征图进行矩阵相乘得到最终的视觉 Tokens, 计算过程如下式 (1) 所示:

$$T = \text{softmax}_{HW} (XW_A)^T X = A^T X, A \in \mathbf{R}^{H \times W \times L}. \quad (1)$$

只有 Tokens 提供的信息不足以完成计算机主板缺陷检测这种需要像素级别的预测任务。因此将 Transformer 的输出 Tokens 通过一个映射器 (Projector) 反变换为特征图, 提供缺陷检测任务所需的像素级细节特征信息。Projector 具体操作流程为对于展平的输入特征图 $z \in \mathbf{R}^{H \times W \times C}$, 通过一个线性映射矩阵 W_Q 将其映射为一个 Query 向量, 将视觉 Transformer 输出的 token 向量 $T \in \mathbf{R}^{L \times C}$ 通过矩阵 W_K 映射为 Key 向量, 对其




图3 VT-FasterBlock特征提取模块网络结构

Fig. 3 Network Structure of the VT-FasterBlock Feature Extraction Module

做自注意力即可得到权重矩阵 $A^* \in R^{HW \times L}$, 将权重矩阵再右乘 $T \in R^{L \times C}$ 即可得到 token 投影到原始特征图的像素级信息 $x^* \in R^{HW \times C}$, 再与原始输入特征图做残差计算得到最终的输出向量 $X_{out} \in R^{HW \times C}$, 计算过程如下式(2)所示:

$$X_{out} = X_{in} + \text{softmax}_L((X_{in} W_Q)(T W_K)^T) T. \quad (2)$$

构建基于视觉 Transformer 的残差路径会导致网络计算量的增加, 考虑实际工业环境下缺陷检测的实时性要求, 引入部分卷积作为基础特征提取操作, 部分卷积的空间结构图如图 4(c) 所示。已有研究工作^[17]表明卷积神经网络提取的特征在通道上具有较高的冗余性。鉴于这一事实, 为了减小计算过程中的内存访问与计算冗余, 本文引入部分卷积进行局部特征提取。具体过程为部分卷积对输入特征图的部分通道应用常规卷积进行空间特征提取, 其余通道做恒等连接。对于输入特征图 $z \in R^{h \times w \times c}$ 来说, 常规卷积的计算量为 $h \times w \times k^2 \times c^2$, 深度可分离卷积(图 4(b))通过使用 c 个滤波器在一个输入通道上进行空间滑动, 将计算量可以降低到 $h \times w \times k^2 \times c$ 。但直接使用深度可分离卷积替换常规卷积会导致严重的精度下降, 采用深度可分离卷积时将通道数变宽为 c^* 以防止精度下降, 但这会引起计算过程中频繁的内存访问, 进而导致整体的

计算速度下降。




图4 部分卷积结构示意图

Fig. 4 Schematic diagram of the partial convolution structure

所提出的方法采用部分卷积降低特征提取过程中的计算复杂度。对于输入特征图 $z \in R^{h \times w \times c}$ 来说, 部分卷积的计算量为 $h \times w \times k^2 \times c_p^2$, 这里 c_p 为参与卷积的通道数, c_p 一般设置为总通道数的 1/4。此时, 相比常规卷积, 部分卷积的计算量仅为常规卷积的 1/16。通过引入部分卷积和视觉 Transformer 构建并行残差特征提取网络 VTNet, 平衡缺陷检测过程中的检测精度和速度需求, 提升计算机主板缺陷检测的特征提取能力, 兼顾计算机主板装配缺陷检测过程中的实时性与准确性。

3.3 多尺度互交叉渐进特征融合网络

多尺度特征融合增强 FPN^[18]是当前基于深度学习的检测算法的通用基础模块。通过多尺度特征融合,网络能够同时兼顾低层的位置信息和高层的语义特征。FPN对主干网络的输出特征通过自上而下的路径对其进行融合,而PANet^[19]在FPN的基础上增加了一个自底向上的特征图融合路径。基线模型YOLOv5通过两个不同的特征融合路径增强了骨干网络的特征表达能力,避免了目标的尺度性和网络深度的硬性匹配,取得较好的检测效果。但在融合过程中,高层和低层特征需要经过多个尺度传播,才能与其他尺度进行交互与融合。因此,在自上而下和自下而上的融合路径中,高层的语义信息和低层的位置特征信息可能会产生退化与丢失,从而影响整体网络的检测效果。

由于非相邻层级的特征图之间的语义差异大于相邻层级特征之间的语义差异^[20],直接使用非相邻层级的特征图进行融合可能导致较大的

特征信息损失。为了解决这个问题,本文结合渐进特征融合网络^[20]和多通道互交叉融合方法^[21],提出了一种新的多尺度互交叉注意力渐进特征融合网络,具体网络结构如下图5所示。该网络通过 Attention-ASFF2 先融合 Low-Level 特征,然后通过 Attention-ASFF3 融合 High-Level 特征,从而避免了跨层级特征的直接融合。此外,该网络还引入了自注意力机制和空间、通道注意力机制,实现了互交叉自适应空间融合。具体来说,对于 Backbone 提取到的不同尺度特征图 $\{C_3, C_4, C_5\}$,在渐进融合流程中,首先将低层特征图 $\{C_4, C_5\}$ 引入特征金字塔。通过运用 Attention-ASFF2 模型,实现了低层特征图 $\{C_4, C_5\}$ 的有效融合,生成了中间特征图 N_4 和 N_5 。接下来利用 Attention-ASFF3 模块对中间特征图 N_4 和 N_5 、新引入的顶层特征图 C_3 进行融合,得到输出的多尺度特征图 $\{P_3, P_4, P_5\}$ 。整个特征融合过程以渐进方式融合了低层和顶层不同尺度的特征。

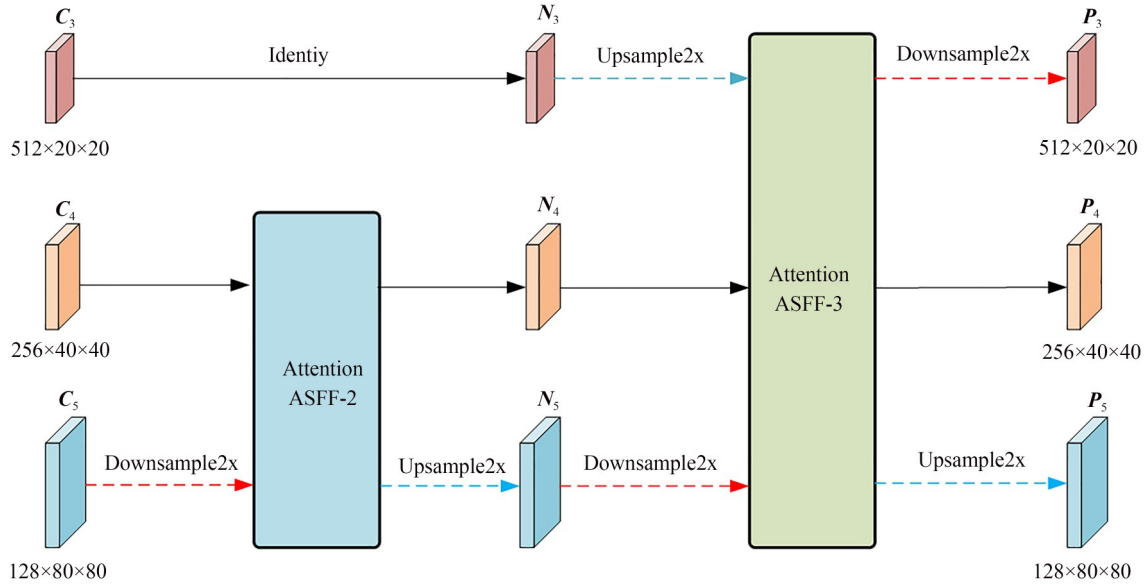


图5 多尺度互交叉注意力渐进特征融合网络

Fig. 5 Multiscale intersection attention asymptotic feature fusion networks

图5展示了所提出的多尺度互交叉渐进特征融合网络结构。为提升关键尺度特征的重要性,降低不同目标尺度矛盾信息的影响,在多级特征渐进融合过程中,本文提出了基于自注意力机制的特征空间权重分配融合方法 Attention ASFF-2

和 Attention ASFF-3。Attention ASFF-2 的网络结构详见图6。

对于输入的不同尺度特征图 C_i 与 C_{i+1} ,若 C_i 的特征维度为 (B, H_1, W_1, C_1) , C_{i+1} 的特征维度为 (B, H_2, W_2, C_2) ,首先对 C_{i+1} 进行下采样,将其




图6 Attention ASFF-2网络结构图

Fig. 6 Network Structure of Attention ASFF-2

尺度变为 (B, H_1, W_1, C_1) ,即将多个尺度的特征图变为同一个尺度。接着对 C_i 进行空间注意力,得到其空间权重,维度为 $(B, H_1, W_1, 1)$ 。用 C_i 的空间注意力权重对 C_i 逐像素进行空间加权增强。对下采样后的 C_{i+1} 特征图,通过通道注意力计算其在每个通道上的注意力权重,维度为 $(B, 1, 1, C)$,然后进行逐通道的加权增强,得到通过空间注意力和通道注意力增强的特征图 C_i^* 和 C_{i+1}^* 。

本文采用自注意力机制计算特征图之间的互交叉权重,依次决定在融合过程中,不同尺度特征的融合重要性,减少目标的不同尺度矛盾信息,增强关键特征的融合。具体操作如下:通过一个核为1的二维卷积Embedding层将输入的特征图编码为向量 $z_1, z_2 \in R^{B \times L}$,其维度为 (B, L) , $L = H \times W \times C$ 。接着通过concat操作将两个特征图编码的向量拼接起来,得到拼接后的特征向量 $z = \text{concat}(z_1, z_2) \in R^{B \times 2 \times L}$ 。然后,通过线性层得到查询向量 q 和键值向量 k 。基于自注意力机制得到特征图的互相关矩阵权重 $[w_{11}, w_{21}, w_{12}, w_{22}]$ 。最后将特征图的互相关矩阵权重乘以通过空间注意力和通道注意力的特征图 C_i^* 和 C_{i+1}^* ,得到互交叉特征融合后的特征图。

Attention ASFF-3的网络架构如图7所示。对于不同尺度的输入特征图 N_3, N_4 和 N_5 ,先对 N_3 和 N_5 分别通过上采样和下采样将其变化为与 N_4 同一维度大小。另外,对 N_3 通过空间注意力得到空间权重,对 N_3 进行空间加权增强;对下采样后的 N_5 通过通道注意力得到通道权重,对 N_5 进行通道加权增强。通过上述操作得到通过空间注意力和通道注意力增强的特征图 N_3' 和 N_5' 。与Attention-ASFF2相同,采用自注意力机制计算不同尺度特征的融合权重。具体来说,将输入的特征图(上采样后的 N_3, N_4 和下采样后的 N_5)通过一个核为1的二维卷积构成的Embedding层编码为向量 $z_1, z_2, z_3 \in R^{B \times L}$,拼接后得到特征向量 $z = \text{concat}(z_1, z_2, z_3) \in R^{B \times 3 \times L}$ 。 z 通过线性层映射后得到查询向量 q 和键值向量 k ;基于 q 和 k 的相关性计算得到交叉互融合权重矩阵 $[w_{11}, w_{21}, w_{31}, w_{12}, w_{22}, w_{32}, w_{13}, w_{23}, w_{33}]$,这个矩阵包含了 N_3', N_4 和 N_5' 三个特征图两两之间进行互交叉融合的权值。基于交叉互融合权重矩阵对 N_3', N_4 和 N_5' 三个特征图进行加权融合。最终对应于 N_3' 和 N_5' 融合后的特征图分别下采样和上采样,得到最终Attention ASFF-3的输出特征图 P_3, P_5 ,对应于 N_4 的融合特征图输出为 P_4 。




图 7 Attention ASFF-3 网络结构图

Fig. 7 Network Structure of Attention ASFF-3

多尺度互交叉渐进特征融合网络通过 Attention-ASFF2 和 Attention-ASFF3 两阶段渐进融合不同层次和尺度的特征图,避免不同层级和尺度的特征图在传播与融合过程中信息的损失,提升目标多尺度特征的显著性,解决计算机主板缺陷检测过程中缺陷目标多尺度的问题。此外, Attention-ASFF2 和 Attention-ASFF3 通过通道注意力、空间注意力对融合过程中的特征图进行加权,增加目标的显著性,解决计算机主板缺陷检测任务中缺陷目标不显著的问题。同时,创新性地引入互交叉注意力机制,实现不同尺度特征

图之间的相互交叉融合,进一步提升网络的检测性能。

4 实验结果分析

4.1 实验数据集

本文实验所采用的数据集是由 Kaggle 开源的计算机主板表面装配缺陷检测数据集^[22]。该数据集包含 1 015 张 RGB 格式的计算机主板质量缺陷图像。考虑实际环境中缺陷样本数量较少,为了提升模型的训练效果并增强泛化能力,




图 8 计算机主板表面装配质量缺陷类型示例

Fig. 8 Examples of types of surface assembly quality defects on computer motherboards

对数据集内的图像进行了多种操作,如翻转、HSV 色彩空间变换、添加噪声和旋转等,实现图像增强。增强后,数据集中的图片数量增加到 4 060 张,主要涵盖的缺陷类型包括风扇固定螺丝丢失、风扇固定螺丝松动、主板固定螺丝丢失、主板固定螺丝松动、风扇接口接线错误和固定螺丝类型错误等。图 8 展示了部分缺陷类型的示例。网络训练时,按照 8:1:1 将数据集划分为训练集、验证集和测试集。

4.2 评价指标

为了更加客观地评估本文方法的检测性能,采用了平均精度均值(mAP)和模型单位时间处理的图像数量(FPS)来全面评估模型的性能。mAP 是基于查准率和查全率对网络在检测过程中的检测精度进行综合评价的指标。以查准率为横坐标,查全率为纵坐标绘制 P-R 曲线。P-R 曲线下的面积即为每个缺陷类别的平均精度(AP)。平均检测精度均值 mAP 值为每个缺陷类别的 AP 的平均值。AP 和 mAP 的计算公式分别表示为式(3)和(4):

$$AP = \int_0^1 p(r) dr, \quad (3)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N}, \quad (4)$$

其中: $p(r)$ 为查准率和查全率的 P-R 曲线, N 为总的缺陷类别数。

4.3 实验环境与实验参数设置

实验环境配置如下:操作系统为 Ubuntu20.04,处理器为 Intel(R) Xeon(R) Gold 6240@2.60 GHz CPU,GPU 为 4 张 NVIDIA GeForce RTX 2080Ti 显卡,每张显卡的显存为 12 GB。使用 PyTorch 1.10.0 搭建网络模型,CUDA 版本为 10.2。为了保证实验结果的一致性,将所有网络均设置为从头开始训练,训练轮次设置为 400 轮,Batch Size 批次大小设置为 16。输入图像分辨率大小为 640×640 ,使用 SGD 随机梯度下降优化器,初始学习率为 $1e-2$,学习率衰减策略为余弦退火算法,动量系数为 0.937,权值衰减系数为 $5e-4$ 。每 10 个 Epoch 训练后,在验证集上进行验证,记录模型的训练损失函数值与验证集上的 mAP 值。网络训练过程的结果如下图 9 所示。




图 9 训练过程中的 Loss 曲线和 mAP 变化情况

Fig. 9 Loss and mAP changes during the training process

由图 9 可知,当训练轮数超过 275 时,网络的训练损失函数值趋近于稳定,mAP 值也趋向于稳定。本文所提出的方法在训练过程中,网络训练损失函数值快速下降,低于基线模型方法的损失函数值,收敛速度更快,网络的检测精度进一

步提升。

4.4 实验结果分析

为了验证所提出方法的正确性与先进性,在计算机主板装配缺陷数据集上,采用相同的实验配置,使用 mAP 和 FPS 作为评价指标,与表面缺

陷检测领域的 SOTA 算法进行对比,实验结果如下表 1 所示。由表 1 可知,与经典的 Faster RCNN 相比,所提出的方法在检测准确率和检测速度方面均表现出色。这是因为 Faster RCNN 采用浅层的 VGG19 网络进行特征提取,不能很好地提取出图像所蕴含的特征信息,同时由于其两阶段的检测结构,计算复杂度高,检测效率低下。相比 YOLO 系列算法,所提方法比 YOLOv3 的平均检测精度提高了 13.8%,比 YOLOv4 的平均检测精度提高了 11.4%,比基线模型 YOLOv5 的平均检测精度提高了 4.6%。对比 YOLOx 来说,所提方法的平均检测精度提升了 5.5%。对比 YOLOv7 来说,所提方法的平均检测精度提升了 1.3%,这是因为所提出的方法采用基于自注意力的 Vision Transformer 结构,结合其长距离建模能力,提取出更具表达能力的特

征图。并且在特征融合阶段,采用渐进多尺度互交叉的自注意力特征融合结构,增强了网络的特征融合能力。相较于文献[23]中提出的 MobileNetV3-YOLOv4 算法,本文所提算法在检测精度上实现了 7.5% 的提升。尽管检测速度有所降低,但本文算法的检测速度依然满足计算机主板检测的实时性要求。与文献[24]所提出的 Swin-Transformer-YOLO 相比,所提方法的检测精度提高了 1.5%。在本文实验设备环境下,所提出方法的检测速度达到了 25 FPS。相比 YOLO 系列算法,所提出方法在检测速度方面有所下降,但检测精度有较大提升,并且检测速度可以满足实时性要求。综合来说,所提方法在检测复杂的计算机主板表面缺陷任务上,实现了较好的检测速度与精度的平衡,能更好地完成实际生产环境下计算机装配过程中的缺陷检测。

表 1 不同缺陷检测算法的检测结果评价

Tab. 1 Comparison of evaluation metrics for different defect detection algorithms

Method	Backbone	mAP(@IoU=0.5)/%	FPS/s
Faster RCNN	VGG19	66.4	12
YOLOv3	DarkNet-53	80.8	52
YOLOv4	CSPDarkNet53	83.2	34
YOLOx	CSPDarkNet53	89.1	51
YOLOv5	CSPDarkNet53	90.0	56
YOLOv7	ELAN-Net	93.3	19
MobileNetV3-YOLOv4 ^[23]	MobileNetV3	87.1	63
Swin-Transformer-YOLOx ^[24]	Swin-Transformer	93.1	14
Ours	VTNet	94.6	25

4.5 消融实验结果分析

为了验证所提出方法改进模型结构的合理性,在计算机主板装配缺陷数据集上,采用相同的实验配置,进行了消融实验。采用 mAP 与各类别上的 AP 作为模型的评价指标。实验结果如下表 2 所示,其中改进 1 指的是在基线模型中引入了本文所提出的基于部分卷积和视觉 Transformer 构成的并行特征提取网络 VTNet,而改进 2 则是指本文所提出的多尺度互交叉渐进特征融合网络。表 2 中列出了 1-11 的各类缺陷和相应检测目标正常的类别序号,其中 1 表示 CPU 风扇固定螺丝丢失,2 表示 CPU 风扇固定螺丝松动,3 表示 CPU 风扇螺丝正常,4 表示 CPU 风扇正常,

5 表示 CPU 风扇接口正常,6 表示 CPU 风扇接口错误,7 表示固定螺丝类型错误,8 表示主板固定螺丝松动,9 表示主板固定螺丝丢失,10 表示主板表面划痕,11 表示主板固定螺丝正常。

由表 2 可知,通过在 YOLOv5 框架中融入本文所提出的 VTNet 特征提取网络,模型的 mAP 提升了 1.73%。这说明了 VTNet 在提取更具表达性特征信息方面的优势。这是由于该特征提取网络引入了由 ViT 构成的残差特征提取路径,进一步结合 ViT 的长距离全局建模能力,进而使得整体的特征提取能力提升。

对于原始的 YOLOv5,由于样本类别 7(即固定螺丝类型错误)的实例数量较少,且与其他

表 2 所提出方法的消融实验结果

Tab. 2 Results of ablation experiments with the proposed method

Methods	mAP (@IoU= 0.5)/%	AP@(IoU=0.5)/%										
		1	2	3	4	5	6	7	8	9	10	11
YOLOv5	90.01	94.00	99.66	99.48	98.60	98.66	89.85	40.74	93.40	93.42	83.51	98.80
YOLOv5+改进 1	91.74	95.32	98.29	99.28	98.49	97.10	86.92	62.69	94.22	94.89	82.76	98.93
YOLOv5+改进 2	91.95	95.40	99.41	98.53	97.63	94.61	79.90	84.79	92.39	94.25	75.26	98.96
YOLOv5+改进 1+改进 2	94.63	96.41	98.48	98.83	98.19	98.46	88.58	84.38	99.71	96.22	82.65	99.05

样本类型的特征相似性较高,导致其检测精度均值 AP 只有 40.74%。引入 VTNet 后,相应类别的平均检测精度达到了 62.69%,说明 VTNet 能提取到该类别缺陷的更具表达性的特征信息。

此外,通过进一步引入所提出的多尺度互交叉渐进特征融合网络,模型的 mAP 得到了 2.89% 的提升。当在 YOLOv5 中单独引入此网络时,模型的检测精度提高了 1.94%。同时,通过引入多尺度互交叉渐进特征融合网络,模型在识别第 7 类样本(固定螺丝类型错误)时的特征显著性得到了明显增强,平均精度也有显著的提升,由原先的 40.74% 提升至 84.79%,验证了多尺度互交叉渐进特征融合网络的有效性。

经过特征提取网络 VTNet 和多尺度互交叉渐进特征融合网络改进后的模型,在类别 7 上的性能提升尤为显著,其平均精度由 40.74% 已提升至 84.38%。此外,在类别 1,8,9,11 上亦实现了不同程度的精度提升。然而,值得注意的是,在原本平均精度较高的类别 2,3,4,5,6,10 中,模型的平均精度略有下降。这一现象可能源于模型内部 VTNet 特征提取网络和多尺度互交叉渐进特征融合网络的改进。这些改进增强了模型对缺陷相似性细节特征的分辨能力,但由于缺陷

特征的相似度过高,也可能对原本正常或易于区分的目标(如 CPU 风扇固定螺丝松动、CPU 风扇螺丝正常、CPU 风扇正常、CPU 风扇接口正常、CPU 风扇接口错误、主板表面划痕)特征产生了一定的影响。尽管如此,改进后的模型在各类缺陷上的平均精度均保持较高水平,有效地避免了在固定螺丝类型错误情况下平均精度偏低的问题。总体而言,模型的平均检测精度均值得到了显著的提升。

综上实验结果表明,本文所提出的针对计算机主板表面缺陷检测任务的算法改进措施,确实能够提升网络检测精度。这两种改进方法相互补充,共同增强了模型在检测相似性细小缺陷方面的能力。

4.6 不同特征融合网络的对比实验分析

本文所提出的多尺度互交叉渐进特征融合网络是在渐进特征融合网络(AFPN)的基础上进行的改进。为了进一步说明本文所提出方法的先进性,在计算机主板装配缺陷数据集上进行了不同特征融合网络的对比实验。实验过程中,对基线模型 YOLOv5 中的特征融合网络进行了修改,以验证不同特征融合网络对实验性能的影响。实验结果如表 3 所示,表中的 1-11 表示的含义与表 2 相同。

表 3 不同特征融合网络对比实验结果

Tab. 3 Experimental results of different feature fusion networks

Methods	mAP		AP@(IoU=0.5)/%										
	(@IoU=	FPS											
	0.5)/%		1	2	3	4	5	6	7	8	9	10	11
YOLOv5+PANet	90.01	56	94.00	99.66	99.48	98.60	98.66	89.85	40.74	93.40	93.42	83.51	98.80
YOLOv5+AFP ^[20]	91.08	43	92.96	95.96	98.90	98.42	96.36	88.37	68.37	91.54	92.83	79.53	98.94
YOLOv5+Ours	91.95	25	95.40	99.41	98.53	97.63	94.61	79.90	84.79	92.39	94.25	75.26	98.96

由表 3 可知,原始 YOLOv5 的特征融合网络为路径聚合网络(PANet),该网络具有自下而上和自上而下的两种特征融合路径。其平均检测精度均值(mAP)值达到了 90.01%。当将 PANet 更换为渐进金字塔特征融合网络(AFPN)后,mAP 提升到了 91.08%,相比原始的特征融合网络提高了 1.07%。这表明渐进金字塔特征融合网络具有更好的性能。进一步引入本文所提出的多尺度互交叉渐进特征融合网络后,mAP 提升了 1.94%,达到了 91.95%。相比渐进金字塔特征融合网络,mAP 值提升了 0.87%。此外,从每一类的 AP 值情况来看,通过引入注意力融合机制,加强特征融合过程中的细节特征融合能力,有助于解决计算机主板缺陷检测过程中的缺陷样本之间的相似性问题,并进一步提高了模型在面对缺陷类别相似性问题时的检测精度。这些结果进一步验证了所提出方法中特征融合网络的先进性和合理性。

4.7 不同特征提取网络的对比实验分析

为了深入探究本文所提出的特征提取方法的优越性,在计算机主板装配缺陷数据集上开展了多组对比实验,比较了不同主干特征提取网络的性能。在实验过程中,对基线模型 YOLOv5 的特征提取网络进行了针对性地调整,以验证不同特征提取网络对模型性能的影响。实验结果如

表 4 所示,其中 1-11 号的含义与表 2-3 保持一致。

由表 4 可知,采用不同的特征提取网络对模型检测精度的影响显著。原始 YOLOv5 模型选用 CSPDarkNet 作为特征提取网络,其平均检测精度均值为 90.01%。然而,当特征提取网络替换为 ResNet 时,平均检测精度略有下降,原因在于 ResNet 模型对于计算机主板缺陷的特征提取能力不足,导致平均精度均值降至 88.77%。替换基线模型的主干网络为 MobileViTV3 后,由于引入了自注意力机制构建全局注意的特征提取主干网络,模型的平均检测精度均值 mAP 提升至 89.61%,并且在固定螺丝错误类型缺陷上的平均精度达到了 54.21%,相比基线模型提升了 13.47%。当引入 Swin-Transformer 后,模型在固定螺丝错误缺陷类型上的平均检测精度进一步提升至 58.29%。接着,采用本文提出的结合部分卷积和视觉 Transformer 的并行特征提取网络,在相似度较高的固定螺丝错误类型上相比 Swin-Transformer 模型提升了 4.4%。尽管由于关注相似度过高目标的特征提取,导致其他一些缺陷目标的显著性稍有降低,使得某些类别缺陷的检测精度略有下降,但总体来看,所提出的特征提取网络使得模型的平均检测精度均值进一步提升至 91.74%,验证了所提出特征提取网络的有效性。

表 4 不同主干特征提取网络的对比实验结果

Methods	mAP		AP@(IoU=0.5)/%										
	(@IoU=0.5)/%	FPS											
			1	2	3	4	5	6	7	8	9	10	11
YOLOv5-ResNet	88.77	17	95.01	98.49	99.27	81.02	95.52	92.96	46.68	93.51	96.95	78.98	98.19
YOLOv5-CSPDarkNet	90.01	56	94.00	99.66	99.48	98.60	98.66	89.85	40.74	93.40	93.42	83.51	98.80
YOLOv5-MobileViT	89.61	41	93.17	98.66	98.99	91.40	95.23	93.02	54.21	93.70	97.25	74.78	95.34
YOLOv5-Swin-Transformer	90.39	16	93.80	96.29	97.06	91.05	95.29	91.41	58.29	93.71	94.26	86.56	96.51
YOLOv5+Ours	91.74	33	95.32	98.29	99.28	98.49	97.10	86.92	62.69	94.22	94.89	82.76	98.93

4.8 可视化实验结果分析

为了以更直观的方式展示所提出方法在实际环境下的检测效果,在相同的实验环境下,选取了基线模型 YOLOv5 和所提出方法在不同缺

陷类型的主板图像实例进行检测。在检测过程中,运用了非极大值抑制算法,并设定了置信度阈值和 IoU 阈值均为 0.5。具体的检测结果如图 10 所示,从上到下依次为原始标注图像的真实

框 Ground Truth、基线模型 YOLOv5 的可视化检测结果和本文方法的可视化检测结果。




图 10 计算机主板装配缺陷检测可视化检测结果

Fig. 10 Computer motherboard assembly defect detection visualization test results

由图 10 可以看出,所提出的模型可以准确地检测出计算机主板装配过程中的缺陷目标。在检测过程中,采用基线模型 YOLOv5 表现出较好的检测效果,但对于主板风扇接口错误和风扇固定螺丝丢失的缺陷存在漏检情况。然而,所提出的算法并未出现上述类型缺陷目标的漏检与错检,本文所提出的检测算法改善了漏检、错检现象。实验结果表明,所提出的方法针对计算机主板表面缺陷检测任务的检测速度达到了 25FPS。针对实际工业环境下的计算机主板表面缺陷检测任务,所提出的方法可以达到较高的检测精度和较快的检测速度。

为了进一步直观展示本文所提出的引入自注意力的特征提取网络和多尺度互交叉渐进注意力特征融合网络的效果,引入 Score-CAM 方法^[25]对模型输出进行热力图可视化分析,结果如图 11 所示。从图中可以看出,引入自注意力特征提取增大了模型的感受野,对于大尺度目标增加了更强的注意力关注程度。引入多尺度互交叉渐进注意力特征融合网络,强化了模型对不同尺度目标的关注程度,增强了模型的特征融合能力。综合引入两种改进网络,网络对不同目标的得分注意力输出都具有较大的提高,抑制了背景信息的表达。




图 11 网络引入不同结构后的输出得分热力图

Fig. 11 Heat map of output scores for different structures introduced by the network

5 结 论

本文针对当前计算机主板装配缺陷检测领

域在智能化和自动化方面所面临的挑战,包括背景干扰信息多、目标不显著、缺陷目标多尺度等问题,从主板图像特征提取和特征融合两个方面

进行改进,提出了端到端的计算机主板装配缺陷检测算法。通过在公开数据集上进行消融和对比实验,得出以下结论:

(1)结合部分卷积和视觉 Transformer 的并行特征提取网络能够同时获取图像的全局信息和局部信息,从而有效地进行特征提取,有助于提高检测精度。

(2)使用互交叉注意力构建的多尺度特征渐进融合网络可以增强模型的多尺度特征融合能力,并捕获特征图存在的细节特征信息,进一步提高了检测精度。

(3)基于并行特征提取网络和互交叉多尺度特征渐进融合网络构建的检测模型在计算机主板表面装配缺陷检测任务上的检测精度优于其他对比方法,算法的平均精度均值(mAP)达到了94.63%,相较于基线模型YOLOv5提升了4.62%,改善了缺陷的漏检和误检现象。

(4)该检测模型在保证高检测精度的同时,也具备良好的检测速度,为实现计算机主板装配缺陷检测的自动化和智能化提供了一种有益的解决方案。

参考文献:

- [1] 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. (in Chinese)
- [2] 卞佰成,陈田,吴入军,等. 基于改进YOLOv3的印刷电路板缺陷检测算法[J]. 浙江大学学报(工学版), 2023, 57(4): 735-743.
BIAN B C, CHEN T, WU R J, *et al.* Improved YOLOv3-based defect detection algorithm for printed circuit board [J]. *Journal of Zhejiang University (Engineering Science)*, 2023, 57(4): 735-743. (in Chinese)
- [3] 陈亚芳,廖飞,黄新宇,等. 多尺度YOLOv5的太阳能电池缺陷检测[J]. 光学精密工程, 2023, 31(12): 1804-1815.
CHEN Y F, LIAO F, HUANG X Y, *et al.* Multi-scale YOLOv5 for solar cell defect detection [J]. *Opt. Precision Eng.*, 2023, 31(12): 1804-1815. (in Chinese)
- [4] 李可,吴忠卿,吉勇,等. 改进U-Net芯片X线图像焊缝气泡缺陷检测方法[J]. 华中科技大学学报(自然科学版), 2022, 50(6): 104-110.
LI K, WU Z Q, JI Y, *et al.* Detection method of weld bubble defect in chip X-ray image based on improved U-Net network [J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2022, 50(6): 104-110. (in Chinese)
- [5] 沈宗礼,余建波. 基于迁移学习与深度森林的晶圆图缺陷识别[J]. 浙江大学学报(工学版), 2020, 54(6): 1228-1239.
SHEN Z L, YU J B. Wafer map defect recognition based on transfer learning and deep forest [J]. *Journal of Zhejiang University (Engineering Science)*, 2020, 54(6): 1228-1239. (in Chinese)
- [6] TU G M, QIN J H, XIONG N. Algorithm of computer mainboard quality detection for real-time based on QD-YOLO [J]. *Electronics*, 2022, 11(15): 2424.
- [7] 陈仁祥,詹赞,胡小林,等. 基于多注意力Faster RCNN的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 167-174.
CHEN R X, ZHAN Z, HU X L, *et al.* Printed circuit board defect detection based on the multi-attentive faster RCNN under noise interference [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(12): 167-174. (in Chinese)
- [8] LUO J X, YANG Z Y, LI S P, *et al.* FPCB surface defect detection: a decoupled two-stage object detection framework [J]. *IEEE Transactions on Instrumentation and Measurement*. IEEE, 2021: 1-11.
- [9] ADIBHATLA V A, CHIH H C, HSU C C, *et al.* Applying deep learning to defect detection in printed circuit boards via a newest model of you-only-look-once [J]. *Mathematical Biosciences and Engineering*

- ing: MBE, 2021, 18(4): 4411-4428.
- [10] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, *et al.* An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale[EB/OL]. 2020: *arXiv*: 2010.11929. <http://arxiv.org/abs/2010.11929>
- [11] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal Speed and Accuracy of Object Detection [EB/OL]. 2020: *arXiv*: 2004.10934. <http://arxiv.org/abs/2004.10934>
- [12] 李彬, 汪诚, 丁相玉, 等. 改进 YOLOv4 的表面缺陷检测算法[J]. 北京航空航天大学学报, 2023, 49(3): 710-717.
- LI B, WANG C, DING X Y, *et al.* Surface defect detection algorithm based on improved YOLOv4[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2023, 49(3): 710-717. (in Chinese)
- [13] 潘睿志, 林涛, 李超, 等. 基于深度学习的多尺寸汽车轮辋焊缝检测与定位系统研究[J]. 光学精密工程, 2023, 31(8): 1174-1187.
- PAN R Z, LIN T, LI C, *et al.* Research on multi size automobile rim weld detection and positioning system based on depth learning[J]. *Opt. Precision Eng.*, 2023, 31(8): 1174-1187. (in Chinese)
- [14] 郭峰, 朱启兵, 黄敏, 等. 基于改进 YOLOV4 的陶瓷基板瑕疵检测[J]. 光学精密工程, 2022, 30(13): 1631-1641.
- GUO F, ZHU Q B, HUANG M, *et al.* Defect detection in ceramic substrate based on improved YOLOV4 [J]. *Opt. Precision Eng.*, 2022, 30(13): 1631-1641. (in Chinese)
- [15] CHEN J R, KAO S H, HE H, *et al.* Run, Don't Walk: Chasing Higher FLOPS for Faster Neural Networks [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, BC, Canada. IEEE, 2023: 12021-12031.
- [16] WU B C, XU C F, DAI X L, *et al.* Visual Transformers: Token-Based Image Representation and Processing for Computer Vision[EB/OL]. 2020: *arXiv*: 2006.03677. <http://arxiv.org/abs/2006.03677>
- [17] HAN K, WANG Y H, TIAN Q, *et al.* GhostNet: more features from cheap operations [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA. IEEE, 2020: 1577-1586.
- [18] LIN T Y, DOLLÁR P, GIRSHICK R, *et al.* Feature pyramid networks for object detection[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA. IEEE, 2017: 936-944.
- [19] LIU S, QI L, QIN H F, *et al.* Path aggregation network for instance segmentation [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA. IEEE, 2018: 8759-8768.
- [20] YANG G Y, LEI J, ZHU Z K, *et al.* AFPN: asymptotic feature pyramid network for object detection [C]. 2023 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Honolulu, Oahu, HI, USA. IEEE, 2023: 2184-2189.
- [21] 孙备, 党昭洋, 吴鹏, 等. 多尺度互交叉注意力改进的单无人机对地伪装目标检测定位方法[J]. 仪器仪表学报, 2023, 44(6): 54-65.
- SUN B, DANG Z Y, WU P, *et al.* Multi scale cross attention improved method of single unmanned aerial vehicle for ground camouflage target detection and localization [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(6): 54-65. (in Chinese)
- [22] XIN Y, ZHOU Z, XIA Y, *et al.* Computer Motherboard Production Defects[EB/OL]. 2023: Kaggle: <https://doi.org/10.34740/KAGGLE/DS/2764127>.
- [23] 周中, 张俊杰, 鲁四平. 基于改进 YOLOv4 的隧道衬砌裂缝检测算法[J]. 铁道学报, 2023, 45(10): 162-170.
- ZHOU Z, ZHANG J J, LU S P. Tunnel lining crack detection algorithm based on improved YOLOv4[J]. *Journal of the China Railway Society*, 2023, 45(10): 162-170. (in Chinese)
- [24] DING J G, LI W, PEI L L, *et al.* Sw-YoloX: an anchor-free detector based transformer for sea sur-

face object detection[J]. *Expert Systems with Applications*, 2023, 217: 119560.


- [25] WANG H F, WANG Z F, DU M N, *et al.* Score-CAM: score-weighted visual explanations

for convolutional neural networks[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. Seattle, WA, USA. IEEE, 2020: 111-119.

作者简介:



陈俊英(1980—),女,内蒙古丰镇人,博士,副教授,硕士生导师,新南威尔士大学访问学者。2004年于西安交通大学获得硕士学位,2010年于西安交通大学获得博士学位,现为西安建筑科技大学信息与控制工程学院教师,主要从事计算机视觉及机器学习方面的研究。E-mail:chenjy@xauat.edu.cn



李朝阳(2000—),男,陕西咸阳人,硕士研究生,主要从事机器视觉及图像处理缺陷检测方面的研究。E-mail:nicholas@xauat.edu.cn