



天津科技大学学报

Journal of Tianjin University of Science & Technology

ISSN 1672-6510, CN 12-1355/N

## 《天津科技大学学报》网络首发论文

题目：基于 YOLOv8 与改进 ResNet50 的电子元器件检测与分类  
作者：郭文琪，杨国威，黄璐瑶，王飞  
DOI：10.13364/j.issn.1672-6510.20240118  
收稿日期：2024-05-16  
网络首发日期：2025-01-15  
引用格式：郭文琪，杨国威，黄璐瑶，王飞. 基于 YOLOv8 与改进 ResNet50 的电子器件检测与分类[J/OL]. 天津科技大学学报.  
<https://doi.org/10.13364/j.issn.1672-6510.20240118>



**网络首发：**在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

**出版确认：**纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。



# 基于 YOLOv8 与改进 ResNet50 的 电子元器件检测与分类

郭文琪<sup>1</sup>, 杨国威<sup>1</sup>, 黄璐瑶<sup>1</sup>, 王飞<sup>2</sup>

(1. 天津科技大学电子信息与自动化学院, 天津 300457; 2. 嘉兴市像景智能装备有限公司, 嘉兴 314500)

**摘要:** 电子元器件种类繁多且没有一致的细粒度分类标准, 为快速满足元器件在不同粒度下的分类需求, 提出一种基于深度学习的 YOLOR-ECA(YOLOv8 and ResNet50 with efficient channel attention)电子元器件检测算法。首先采用 YOLOv8 网络定位元器件位置, 然后采用 ResNet50 网络对定位获取的元器件进行识别分类, 通过元器件种类的增减满足不同细粒度的分类标准。为提升模型对尺寸小、特征相似元器件的细节特征提取能力, 分类网络引入 ECA 注意力机制, 并对残差结构的捷径连接部分进行改进; 为避免神经元失活, 采用 GELU(Gaussian error linear units)激活函数。实验结果表明, 改进的 YOLOR-ECA 模型的检测准确率为 96.6%, 并且对于小尺寸元器件的识别精度最高可达 100%, 对于具有特征相似性元器件的误检率最低可降到 0.01%, 能实现电子元器件在不同细粒度分类标准下的高效检测。

**关键词:** 深度学习; 电子元器件; YOLOv8; ResNet50

中图分类号: TP391.4

文献标志码: A

文章编号: 1672-6510(2024)00-0000-00

## Electronic Component Detection and Classification Based on YOLOv8 and Improved ResNet50

GUO Wenqi<sup>1</sup>, YANG Guowei<sup>1</sup>, HUANG Luyao<sup>1</sup>, WANG Fei<sup>2</sup>

(1. College of Electronic Information and Automation, Tianjin University of Science & Technology, Tianjin 300457, China;  
2. Jiaxing Sci-jet Intelligent Equipment Co., Ltd., Jiaxing 314500, China)

**Abstract:** Electronic components have various types, and the types have no consistent fine-grained classification standard. To quickly classify the components at different granularities, a YOLOR-ECA (YOLOv8 and ResNet50 with Efficient Channel Attention) electronic component detection algorithm based on deep learning is proposed. Firstly, YOLOv8 network is used to locate position of components. Secondly, ResNet50 network is used to identify and classify components obtained through positioning. The design method can meet different fine-grained classification standards by increasing or decreasing types of components. In order to extract the detailed features of components with small-sized and feature similarity, ECA attention mechanism is added to classification network, and shortcut connection of residual structure is modified. To avoid neuronal inactivation, the GELU (Gaussian Error Linear Units) activation function is used. The experiments show that the improved YOLOR-ECA model has a detection accuracy of 96.6%. The highest recognition accuracy for small-sized components can reach 100%, and the lowest false detection rate for components with feature similarity can be reduced to 0.01%. YOLOR-ECA can efficiently detect electronic components under different fine-grained classification standards.

收稿日期: 2024-05-16; 修回日期: 2024-10-24

基金项目: 国家自然科学基金资助项目(51805370); 天津市自然科学基金资助项目(20JCQNJC00120)

作者简介: 郭文琪(1999—), 女, 甘肃定西人, 硕士研究生; 通信作者: 杨国威, 副教授, yangguowei@tust.edu.cn

**Key words:** deep learning; electronic component; YOLOv8; ResNet50

21 世纪是智能化信息时代，电子产品作为智能化的代表产物，在日常生活、航天军事、工业制造、医学设备等领域具有广泛应用。电子元器件作为印制电路板的基础零部件，其类别检测在电子设备工业生产中具有广泛需求和重要应用价值。

电子元器件检测方法大致分为两类，一类是传统的机器学习方式，另一类是基于深度学习的识别方式。传统的机器学习方式的每个检测步骤独立，依赖人工设计的提取器对图像的特征进行提取，常见的经典算法有模板匹配法<sup>[1]</sup>、支持向量机(support vector machine, SVM)<sup>[2]</sup>。王志国<sup>[3]</sup>分析待检测元器件的颜色信息，将其与模板信息进行图像匹配，以此判断元器件是否缺失；Yin<sup>[4]</sup>采用多级图像匹配方法，通过粗匹配找到与标准元器件相似的区域，再进行精确匹配，判断是否为某个特定组件。这类识别方法存在对图像质量要求高、外形相似目标识别效果不佳以及提取工艺繁琐等不足，逐渐被基于深度学习的识别方式代替。

深度学习技术的发展使基于深度学习的电子元器件检测取得丰硕的研究成果。陈文帅等<sup>[5]</sup>利用 k-means 算法对 Fast RCNN 和 YOLOv3 的锚框进行改进设计，有效提高了元器件的检测准确率。张志杰等<sup>[6]</sup>针对元器件体积小、外观相似的检测难点，提出 ETS-Net 检测算法，通过引入深度可分离卷积，在降低模型复杂度的同时，有效提升了检测精度。张明路等<sup>[7]</sup>利用深度可分离卷积代替传统卷积，逆残差结构代替 CSP darknet52 主干网络，并加入注意力机制，有效提高元器件的检测精度和效率。相较于人工提取图像特征的传统方法，基于深度学习的检测方法通过网络模型自动提取电子元器件特征，克服了图像质量要求高、泛化能力差等弊端。在实际工程应用中，电子元器件种类繁多且缺乏通用的细粒度分类<sup>[8]</sup>标准，以上研究直接采用多分类检测方法，可能会产生因分类标准不同而导致数据集需要被重新标注的问题，不能快速满足元器件在不同粒度下的分类需求。

针对存在的问题，本文提出 YOLOR-ECA (YOLOv8 and ResNet50 with Efficient Channel Attention)电子元器件检测方法，通过 YOLOv8 定位检测和 ResNet50 识别分类，实现电子元器件在不同

细粒度分类标准下的类别检测。将分类网络引入 ECA 注意力机制、修改残差块下采样部分、替换激活函数，解决信息丢失问题，旨在提升尺寸小、特征相似元器件的检测准确率。

## 1 基于 YOLOR-ECA 的电子元器件检测

### 1.1 数据集构建及检测难点

为满足工业常规检测需求，本研究对电容、电阻、电感、集成电路、二极管等 8 类常见电子元器件进行识别分类。定位检测数据集是包含大量常见元器件的电路板图像，为提升模型泛化能力，将采集到的 241 张电路板图像通过水平翻转、垂直翻转、旋转(90°、180°)和裁剪等数据集扩充方式，扩充到 2300 张，并按 7: 2: 1 的比例划分成训练集、验证集和测试集。分类阶段自建两组数据集，第一组按照元器件基本功能和特性进行粗粒度图像分类，分出电容、电阻、二极管、振荡器等 8 类常见元器件；第二组按照元器件尺寸、用途等，将划分出的 8 个大类进一步细分为 60 个小类，即进行细粒度图像分类，整理好的数据集图像经过旋转、缩放、噪声添加和亮度调整等方式进行数据集扩充后，按 4:1 的比例划分出训练集、验证集，测试集由 YOLOv8 定位检测获取到的包含单个目标元器件的图像组成。部分元器件划分见表 1。

表 1 电子元器件种类

Tab. 1 Types of electronic components

常见电子元器件	细粒度分类
电容(11 类)	电解电容、钽电容、C0201、C0402、C01005……
电阻(12 类)	排型电阻、R0603、R0402、R0201、R01005……
二极管(13 类)	LED0603、LED0805、开关二极管、整流二极管……
晶体管(7 类)	场效应管、SOT23、SOT25、SOT223、SOT323……
集成电路(12 类)	显卡、CPU、充电管理芯片、电源管理芯片……
电感(2 类)	功率电感、贴片电感
振荡器(2 类)	无源晶振、有源晶振



对数据集进行分析后发现,电子元器件存在尺寸小、特征相似的检测难点,影响检测精度。数据集图像示例如图1所示,图1(a)为贴片电容C0201和C0603,C0201的尺寸大小仅为 $0.6\text{ mm}\times 0.3\text{ mm}$ ,不足C0603的一半,这类元器件在图像中像素表示较少,定位裁剪过程会进一步丢失像素信息导致图像模糊,有效特征信息难以提取。图1(b)和图1(c)分别为晶体管SOT23和SOT323两个特征相似的元器件,这两类元器件在尺寸上略有差异,但纹理特征、物理结构相似度较高,难以提取具有区分度的特征信息,易产生误检。




图1 数据集图像示例

Fig. 1 Example of dataset image

## 1.2 电子元器件分类检测算法流程

定位检测是电子元器件识别分类的前提,通过位置信息的确定,可有效滤除背景等冗余信息的干扰,提升检测精度。本文提出的YOLOR-ECA电子元器件检测算法主要包含三部分:(1)YOLOv8检测网络获取每个电子元器件的位置信息;(2)根据预测框坐标,将包含单个目标元器件的矩形框裁剪出来,作为分类网络测试集;(3)采用改进的ResNet50模型,对单个目标元器件进行识别分类。具体流程如图2所示。



图2 电子元器件检测算法流程图

Fig. 2 Flowchart of electronic component detection algorithm

## 2 深度学习模型

### 2.1 YOLOv8 网络模型

多分类检测模型需要进行大量数据标注,当分类标准改变时需要重新进行标注,增加数据处理的成本和工作量,并且人工进行数据标注容易出现错误或遗漏,影响识别结果的准确性。因此,本研究采用先检测后分类的方法。YOLOv8用于定位检测,所有元器件都标为同一类,用于获取电路板上元器件的相关位置信息。

YOLOv8是一种检测速度快、灵活性高的网络模型,核心组件包括Backbone、Neck和Head三部分。Backbone部分采用C2F模块,通过更多分支跨层连接,丰富模型梯度信息<sup>[9]</sup>。Neck网络仍通过FPN-PAN(feature pyramid network-path aggregation network)双重特征金字塔结构<sup>[10]</sup>融合多尺度信息,加强特征提取能力。Head部分改用解耦头结构<sup>[11]</sup>和无锚框检测头机制,分类信息通过 $20\times 20$ 、 $40\times 40$ 、 $80\times 80$  3种尺度输出。不同尺寸特征图具有不同大小感受野和分辨率,尺度越大,分辨率越高,具有更多细节特征,利于小目标元器件检测;尺度越小,分辨率越低,更擅长获取大型目标元器件的全局信息。

### 2.2 改进的ResNet50网络

定位检测后,选用ResNet网络实现分类识别任务。综合模型性能和工业部署需求,浅层网络特征提取能力不足,更深层网络参数量较多,不利于快速检测<sup>[12]</sup>,确定ResNet50作为元器件识别的基础网络模型。ResNet<sup>[13]</sup>模型结构优势在于直接学习输入层与输出层之间的残差函数,而上层学习到的特征通过跳跃连接直接与输出层相连,网络层数增加后网络性能也不会变差。数据集的优势在于不需要繁琐的数据标注工作,每类元器件单独放置,当分类标准改变时,通过调整元器件类别可快速适应新的分类需求。

#### 2.2.1 ECA 注意力机制的添加

ECA注意力机制<sup>[14]</sup>的结构图如图3所示,该模块是一种跨通道交互的高效通道注意力模块。不同于SE模块使用全连接层进行降维处理,ECA采用自适应选择一维卷积核的方法。在全局平均池化后通过一维卷积直接获取每个通道和它的 $K$ 个邻接通道间的相互作用关系,再采用Sigmoid激活函数归一化处理,得到每个通道的特征权重,避免了维度缩减导致的通道信息丢失。自适应选择卷积核的计算公式为

$$K = \left\lfloor \frac{\log_2(c)}{\gamma} + \frac{b}{\gamma} \right\rfloor \quad (1)$$

式中： $K$  表示卷积核数量，只能为奇数； $\gamma = 2$ ； $b = 1$ ； $c$  为通道数。




图3 ECA 注意力机制结构图

Fig. 3 ECA Attention Mechanism Structure Diagram

本文研究的电子元器件具有目标尺寸小、特征相似的检测难点，需要提取更多有效的细微特征。ResNet50 第一层经过一个  $7 \times 7$  的卷积，感受野较大，捕捉到更多全局信息而容易忽略局部细节特征<sup>[15]</sup>。针对此不足，将 ECA 注意力机制添加到网络的每一个残差块内，以及主干网络的最大池化层与平均池化层之前。ECA 注意力机制可以获取元器件的高维语义特征，通过自适应调整特征通道权重，获取更多具有辨识度的细节特征，提升尺寸小、特征相似元器件的识别精度。添加注意力机制后的 ResNet50 网络结构参数见表 2。此外，由式(1)可知，通道数越多，一维卷积核越大，而过大的感受野不利于图像细节特征的表达，对外形、颜色相似度较高的元器件，难以生成区分度较高的特征信息，易误检。因此，本文不采用自适应选择卷积核的方法，直接指定卷积核大小为  $3 \times 3$ 。

表 2 改进的 ResNet50 网络结构参数

Tab. 2 Network architecture of improved ResNet50

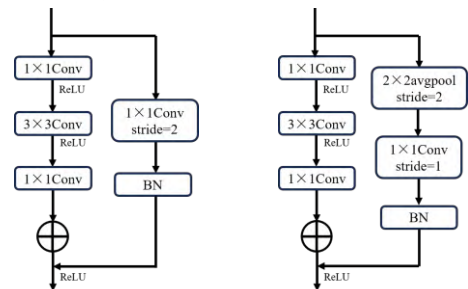
模块名称	输出大小	模型结构
Conv_Block	112×112	$7 \times 7, 64, \text{stride} = 2$ ECA Max pooling
ResNet-Block1	56×56	$1 \times 1, 64$ $3 \times 3, 64$ $1 \times 1, 256$ <sup>×3</sup> ECA
ResNet-Block2	28×28	$1 \times 1, 128$ $3 \times 3, 128$ $1 \times 1, 512$ <sup>×4</sup> ECA

ResNet-Block3	$14 \times 14$	$1 \times 1, 256$ $3 \times 3, 256$ $1 \times 1, 1024$ <sup>×6</sup> ECA
ResNet-Block4	$7 \times 7$	$1 \times 1, 512$ $3 \times 3, 512$ $1 \times 1, 2048$ <sup>×3</sup> ECA
输出层	$1 \times 1$	ECA Average pooling $154 - d, FC$

### 2.2.2 下采样的改进

原始残差网络中捷径连接的下采样操作由  $\text{stride} = 2$ 、大小为  $1 \times 1$  的卷积核完成， $1 \times 1$  的卷积核进行步长为 2 的卷积操作时，跳过一些像素点，此时特征图尺寸减小，卷积核只能捕捉到输入图像的部分特征。

电子元器件具有尺寸小、特征相似的检测难点，使具有区分度的有效特征点数量较少， $\text{stride} = 2$  的下采样操作易因跳过一些像素点造成特征信息的丢失<sup>[16]</sup>。因此，本文将  $1 \times 1$  卷积核的步长修改为  $\text{stride} = 1$ ，此时卷积核逐个像素点遍历图像，可避免特征信息的丢失。下采样操作通过在  $1 \times 1$  的卷积核前加入  $\text{stride} = 2$ 、大小为  $2 \times 2$  的平均池化层实现，该池化层在不引入额外参数<sup>[14]</sup>的情况下能够有效保留图像特征。改进前后的残差结构如图 4 所示。



(a)改进前残差结构 (b)改进后残差结构

图 4 改进前后的残差结构

Fig. 4 Residual structure before and after improvement

### 2.2.3 激活函数的替换

ReLU 激活函数的特性在于输入为负数时输出为 0，此时激活函数不再对输入信号作出响应<sup>[17]</sup>，而元器件具有目标尺寸小、类内相似度高特点，有效信息相对稀疏和细微，神经元失活容易丢失关键信息，限制模型对电子元器件的表达能力。

本文选用 GELU 激活函数，该函数与高斯分布相联系，当输入为负数时，始终有一定的输出值，避免训练时出现梯度消失的问题，确保模型能够充

分利用输入的所有特征信息,提升模型的泛化能力和收敛能力。GELU 计算公式为

$$f(x) = x\phi(x) \approx 0.5x(1 + \tanh(\sqrt{\frac{2}{\pi}}(x + 0.044715x^3))) \quad (2)$$

式中:  $\phi(x)$  表示正态分布的概率分布函数。

### 3 实验设计与分析

#### 3.1 环境搭建

在 Ubuntu22.04 操作系统下,搭建基于 CUDA11.6 与 PyTorch1.12.1 的深度学习算法框架并进行实验,其中开发语言环境为 Python3.7, GPU 型号为 NVIDIA TITAN XP(显存 12 GB),用于加快模型训练速度。

#### 3.2 实验参数设置

基于 YOLOv8 定位检测与改进的 ResNet50 识别分类的参数设置见表 3。定位检测过程为预测到尽可能多的边界框,设置置信度阈值为 0.25;设置参数 save-crop 为 True,用于截取包含单个目标元器件的矩形框。

表 3 网络训练参数设置

Tab. 3 Network training parameter settings

参数名称	参数设置	
	YOLOv8	改进的 ResNet50
输入图像尺寸	640 像素×640 像素	224 像素×224 像素
训练批次(batch size)	32	16
学习率(learning rate)	0.01	0.0001
训练轮次(epochs)	300	60
优化器(optimizer)	SGD	Adam

#### 3.3 定位检测结果与分析

YOLOv8 网络模型训练的评价指标主要有精确率( $P$ )、召回率( $R$ )和平均精度均值(mAP),其中 mAP 表示训练后的模型在所有类别上好坏的平均值,用  $P_{avm}$  表示;定位检测阶段进行单分类目标检测, $n = 1$ ,则平均精度均值(mAP)与平均精度 AP 相等。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (3)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (4)$$


$$P_{avm} = \frac{1}{n} \sum_{j=1}^n P_{av}(j) = P_{av} = \int_0^1 P(R) dR \quad (5)$$

式中:  $N_{TP}$  表示真阳性数量,  $N_{FP}$  表示假阳性数量,  $N_{FN}$  表示假阴性数量,  $P_{av}$  表示平均精度。

将自建的电路板图像数据集输入 YOLOv8 网络

进行训练,得到精确率、召回率、mAP@0.5 的训练结果分别为 97.1%、98%、98.4%。

为进一步了解 YOLOv8 的定位检测训练效果,训练集和验证集的位置损失曲线如图 5 所示。由图 5 可知:在迭代次数为 50 时,位置损失曲线快速收敛;迭代次数为 200 时,各项损失值已趋于稳定且接近于 0,模型达到很好的拟合效果。此时,训练集和验证集的位置损失分别为 0.017、0.005,说明 YOLOv8 网络模型对目标元器件定位效果良好,可以准确提供所需元器件的位置信息。实际检测结果如图 6 所示。




(a) 训练集位置损失

(b) 验证集位置损失


图 5 YOLOv8 训练损失值

Fig. 5 Training loss value of YOLOv8



(a) 小尺寸元器件

(b) 常规尺寸元器件



(c) 大尺寸元器件

(d) 特征相似元器件

图 6 YOLOv8 定位检测结果

Fig. 6 Positioning detection results of YOLOv8

#### 3.4 分类识别结果与分析

##### 3.4.1 消融实验

为验证改进后 ResNet50 算法的提升效果,在粗粒度图像分类和细粒度图像分类两组数据集上,以训练精度、验证精度和检测准确率作为评价指标,对 3 种改进方法分别进行消融实验,实验结果见表 4。

由表 4 可知,每种改进方法相较原网络都有一

定的提升, 加入 ECA 注意力机制的提升效果最好。最后结合 3 种改进方法的优势, 使粗粒度图像分类检测准确率提升 3.0%, 细粒度图像分类检测准确率提升 3.3%。比较两组数据集检测结果, 第二组数据

集提升效果更好, 是由于本文对 ResNet50 的改进侧重于捕捉图像细微特征的差异, 而粗粒度图像数据集类间特征差异较大, 需要关注更多全局信息。

表 4 消融实验结果


Tab. 4 Results of ablation experiment

数据集	模型	训练精度/%	验证精度/%	检测准确率/%
粗分类	ResNet50	93.9	96.5	92.6
	ResNet50+ECA	96.2	98.8	94.2
	ResNet50+改进下采样	94.9	97.6	93.9
	ResNet50+GELU	94.2	97.0	93.4
	本文算法	97.1	98.1	95.6
细分类	ResNet50	92.6	94.6	93.3
	ResNet50+ECA	94.3	96.1	96.0
	ResNet50+改进下采样	93.1	96.4	94.9
	ResNet50+GELU	93.8	97.5	95.1
	本文算法	95.5	98.1	96.6


3.4.2 检测结果可视化

为验证改进的 ResNet50 针对元器件检测难点的有效性, 对细粒度分类数据集的小尺寸元器件, 分别在 3 种不同网络结构下进行检测, 结果如图 7


所示, 其中被测元器件类型从左向右依次为电容 C01005、电阻 R0201 和整流二极管 rectifier diode。改进后的 ResNet50 对小尺寸元器件的检测精度有良好的提升效果。



(a)ResNet 检测结果



(b)ResNet+ECA 检测结果



(c)ResNet+ECA+GELU+修改下采样检测结果

图 7 改进前后模糊图像的检测结果

Fig. 7 Blurred image detection results before and after improvement







具有特征相似性元器件的检测结果见表 5, 共展示了 3 组相似元器件分别在 3 种不同改进方式下的检测结果。第一行为待检测元器件改进前后的识别

精度  $P_{acc}$ , 第二行为改进前后待检测元器件被检测为与其相似元器件的误检率  $P$ 。由表 5 可知, 改进后待检测元器件的识别精度均有所提升, 且被检测为相

似元器件的概率值也相应降低,证明本文改进方法 的有效性。

表 5 改进前后特征相似图像检测结果

Tab. 5 Image detection results of similar features before and after improvement

序号	元器件类别	对比图像	ResNet	ResNet+ECA	ResNet+ECA+GELU+ 修改下采样
(a)	C0603		$P_{acc}=87.50\%$	$P_{acc}=92.30\%$	$P_{acc}=97.10\%$
	C0805		$P=10.30\%$	$P=5.52\%$	$P=1.34\%$
(b)	整流二极管		$P_{acc}=92.90\%$	$P_{acc}=99.50\%$	$P_{acc}=100.00\%$
	开关二极管		$P=0.91\%$	$P=0.47\%$	$P=0.03\%$
(c)	SOT323		$P_{acc}=77.10\%$	$P_{acc}=94.30\%$	$P_{acc}=99.80\%$
	SOT23		$P=1.38\%$	$P=0.96\%$	$P=0.01\%$

### 3.5 对比实验

为验证本文方法在电子元器件分类中的检测性能,将本文模型与YOLOv8、Faster RCNN和SSD网络在细粒度分类数据集上进行识别检测,其可视化检测结果如图8所示,其中(a)、(b)、(c)图为本文提出的YOLOR-ECA算法的最终检测结果,(d)图为YOLOv8直接分类的检测结果,在具有特征相似性的SOT23和SOT323上产生了误检,此外,Faster RCNN和SSD网络在特征相似和小尺寸元器件上的检测精度也低于YOLOR-ECA算法。

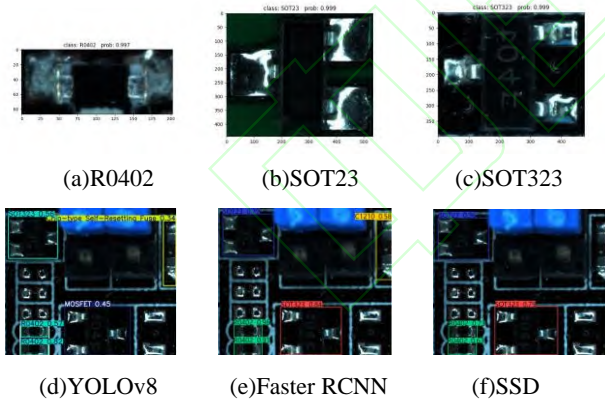


图 8 可视化检测结果

Fig. 8 Visualization of test results

不同网络模型性能对比实验结果见表6。由表可知,本文提出的YOLOR-ECA算法对电子元器件的检测准确率最高;其次是双阶段检测网络Faster RCNN,但该模型复杂度较高,不利于部署且运行效率低。YOLOv8和SSD网络为单阶段检测网络,而电路板上经常出现常见元器件数量远多于其他复杂或特殊元器件数量的情况,出现类别不平衡问题,影响单阶段检测模型的检测性能,因此识别效果较

差。

表 6 不同网络的性能对比实验

Tab. 6 Performance comparison test of different networks

网络模型	训练精度/%	验证精度/%	检测准确率/%
YOLOR-ECA	95.5	98.1	96.6
YOLOv8	86.4	90.5	86.0
Faster RCNN	94.7	98.0	96.3
SSD	84.2	87.6	85.4

## 4 结论

面向电子元器件识别的问题,通过对电子元器件检测难点的分析,提出YOLOR-ECA两段式检测方法。定位检测采用具有实时检测功能的YOLOv8模型,实现电路板上电子元器件的快速定位;识别阶段采用准确率较高的ResNet50模型,并引入通道注意力机制、替换激活函数、改进残差块的下采样部分。结果表明,改进后的YOLOR-ECA算法模型参数量为23.631M,同时检测准确率达96.6%,相较改进前有3.3%的提升。此外,该模型检测速度能达到124帧/s,具有高效的检测性能,在实际工程应用中,可以更快实现不同细粒度分类标准下的元器件检测,并准确识别尺寸小、特征相似的各类元器件,保证电路板质量检测的顺利进行。

### 参考文献:

[1] 张晶,李志敏,黄凡. 一种改进的自适应模板匹配法[J].



- 微计算机信息,2008,24(27):166-167.
- [2] 崔建明,刘建明,廖周宇. 基于 SVM 算法的文本分类技术研究[J]. 计算机仿真,2013,30(2):299-302.
- [3] 王志国. 基于机器视觉的 PCB 元器件检测方法研究[D]. 太原:中北大学,2019.
- [4] YIN H M. A template-matching-based fast algorithm for PCB components detection[J]. *Advanced materials research*, 2013, 690/691/692/693: 3205-3208.
- [5] 陈文帅,任志刚,吴宗泽,等. 基于深度学习的极性电子元器件目标检测与方向识别方法[J]. *自动化学报*,2021,47(7):1701-1709.
- [6] 张志杰,顾寄南,李静,等. 基于深度学习的电子元器件快速检测算法研究[J]. *电子测量技术*,2022,45(10):93-101.
- [7] 张明路,郭策,吕晓玲,等. 改进的轻量化 YOLOv4 用于电子元器件检测[J]. *电子测量与仪器学报*,2021,35(10):17-23.
- [8] 罗建豪,吴建鑫. 基于深度卷积特征的细粒度图像分类研究综述[J]. *自动化学报*,2017,43(8):1306-1318.
- [9] 马超伟,张浩,马新明,等. 基于改进 YOLOv8 的轻量化小麦病害检测方法[J]. *农业工程学报*,2024,40(5):187-195.
- [10] 李慧琴,宋赵铭,刘存祥,等. 基于 YOLOv8n 的番茄果实检测模型改进[J/OL]. *河南农业大学学报*,1-14[2024-05-15]. <https://doi.org/10.16445/j.cnki.1000-2340.20240511.002>.
- [11] SONG G L, LIU Y, WANG X G. Revisiting the sibling head in object detector[C]//*IEEE. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. New York: IEEE,2020: 11563-11572.
- [12] 朱传军,刘荣光,成佳闻,等. 基于 SimAM 模块与 ResNet34 网络的混合缺陷检测模型[J]. *现代制造工程*,2023(2):1-9.
- [13] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//*IEEE. Proceedings of the IEEE conference on computer vision and pattern recognition*. New York: IEEE,2016: 770-778.
- [14] 罗维平,徐洋,陈永恒,等. 基于迁移学习和改进 ResNet50 网络的织物疵点检测算法[J]. *毛纺科技*,2021,49(2):71-78.
- [15] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//*IEEE. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. Seattle:IEEE, 2020: 11534-11542.
- [16] 赵正伟,朱宏进,杨根滕,等. 基于改进 Res2Net 模型的淡水鱼类图像分类研究[J]. *软件工程*,2022,25(7):28-32.
- [17] 刘韵婷,葛忠文,郭辉. 基于 CA-ResNet50 的轮胎激光散斑图的分类研究[J]. *电子测量技术*,2023,46(4):169-174.