文章编号:1671-4598(2025)07-0081-09 DOI:10.16526/j.cnki.11-4762/tp.2025.07.010 中图分类号:TP391.41 文献标识码:A

基于改进 YOLOv5s 的弱电板卡表面缺陷检测方法

刘 真[1],宋 凯[1],刘 磊[2],鞠军燕[2]
(1. 中车青岛四方机车车辆股份有限公司,山东 青岛 266000;
2. 中国电子科技集团公司 第三十三研究所,太原 030032)

摘要:针对传统弱电板卡表面缺陷检测方法效率低、精度差且对元器件的外观缺陷检测能力不足等问题,对YOLOv5s算法进行了技术改进研究;引入CBAM注意力机制强化了对板卡关键特征的提取能力,结合CotNet模块提升了模型小目标检测的能力,采用动态检测头实现多尺度目标自适应检测,并利用SIoU损失函数优化了模型的收敛速度和检测精度,更好地处理了目标框的回归问题;经实验测试,改进算法在实验室自制的板卡数据集上的准确率达到95.7%,相比原算法,mAP_{50}与$mAP_{50:95}$分别提升了4.3%与2.5%,有效提升了弱电板卡元器件表面缺陷检测的准确性和可靠性,对未来电路板元器件的表面缺陷检测研究具有一定参考价值。

关键词:弱电板卡;表面缺陷检测;YOLOv5s;注意力机制;损失函数;动态检测头

Surface Defect Detection Method for Low-voltage Circuit Boards Based on Improved YOLOv5s

LIU Zhen[1], SONG Kai[1], LIU Lei[2], JU Junyan[2]
(1. Qingdao Sifang Locomotive and Rolling Stock Co., Ltd., Qingdao 266000, China;
2. The 33th Research Institute of China Electronics Technology Group Corporation (CETC), Taiyuan 030032, China)

Abstract: Low-voltage boards have the disadvantages of low efficiency, poor accuracy, and insufficient capability in detecting appearance defects of electronic components in traditional surface defect detection methods. To solve these issues, this paper makes a technical improvement of the YOLOv5s algorithm. The convolutional block attention module (CBAM) attention mechanism is introduced to enhance the extraction of key board features. The contextual transformer network (CotNet) module is integrated to improve the capability of small target detection. The dynamic detection head is adopted to achieve the detection of adaptive multi-scale targets. The structure-based intersection over union (SIoU) loss function is utilized to optimize the model convergence speed, detection accuracy, and bounding box regression. Experimental results show that the improved algorithm achieves an accuracy of 95.7% on a custom board dataset, and compared with the original algorithm, it improves the mAP_{50} and $mAP_{50:95}$ by 4.3% and 2.5%, respectively, thus effectively enhancing the accuracy and reliability of surface defect detection for low-voltage board components, which provides a reference value for the defect detection of electronic components on circuit boards in the future.

Keywords: low-voltage circuit board; surface defect detection; YOLOv5s; attention mechanism; loss function; dynamic detection head

0 引言

在当今电子信息技术飞速发展的时代背景下,电路板作为各类电子设备的核心组件,其重要性日益凸显。随着电子设备向着智能化、微型化、高性能化方向不断发展,电路板表面的元器件也呈现出高度集成化的发展趋势。这种高度集成的设计在提升设备性能的同时,也使得电路板的复杂程度呈指数级增长,随之而来的是更高的故障风险,一些微小的缺陷,如焊点焊接不良、元件引脚误接、引脚断裂等,都可能影响整个系统的稳定

收稿日期:2025-01-15; **修回日期**:2025-03-06。
作者简介:刘 真(1990-),男,硕士,工程师。
通讯作者:宋 凯(1980-),男,硕士,高级工程师。
引用格式:刘 真,宋 凯,刘 磊,等.基于改进 YOLOv5s 的弱电板卡表面缺陷检测方法[J].计算机测量与控制,2025,33(7):81-89.

运行。特别是在航空航天、智能车辆、工业控制等关键领域，电路板的可靠性直接关系到整个系统的安全性和稳定性。因此，板卡缺陷的精准定位与识别对后期维修的难度有着至关重要的影响[1-4]。

传统的缺陷检测方法主要依赖于人工目视检测，这种方法存在诸多局限性，不仅检测效率低下，而且检测质量也不稳定，容易受到检测人员经验水平、疲劳程度等主观因素的影响，对于微型化、高密度封装的现代电路板，人眼分辨能力已难以满足检测需求。随着计算机技术和人工智能技术的快速发展，越来越多的学者开始将计算机视觉技术应用于板卡外观缺陷检测领域。文献[5]提出了一种改进的 YOLOv4 检测模型，实现了对板卡器件的漏装、错装、偏移、歪斜和极性反转 5 种缺陷的精确识别和定位，通过增加小目标检测尺度，采用 K-means ＋ ＋算法[6]对数据集的目标框尺寸进行聚类分析，显著提升了微小元器件的识别能力，采用基于特征向量的智能匹配方法，通过获取元器件的精确位置信息，提取其方位特征和极性特征，构建多维特征向量空间，计算实际检测结果与标准模板的特征向量相似度，实现了对元器件安装状态的精确判断。文献[7]提出了一种改进的 YOLOv5 检测模型，采用轻量化的 EfficientNetV2 结构替代了原模型的主干网络，这一改进显著降低了模型的计算复杂度，针对 PCB 板表面的六类缺陷（包括毛刺、缺口、短路、余铜、漏焊、开路等），引入了坐标注意力机制，该机制更好地捕捉了各缺陷的空间位置信息，增强了模型对小尺度目标的特征提取能力，改进后的模型在检测速度、检测精度、鲁棒性等方面都有很大提升。文献[8]提出了一种基于 YOLOv5 与混合注意力机制融合的印制电路板检测模型，对 PCB 板的缺孔、鼠咬、假铜等 6 种缺陷进行了检测，以不同的维度以及更高的感受野保证了缺陷提取的完整性。模型引入了自适应双向特征融合模块，实现了不同层级特征图之间的深度交互与融合，该模块能够根据检测目标的尺度特性，自适应地为每个特征图分配不同的权重系数，从而充分挖掘和利用多尺度特征信息，增强网络模型对微小缺陷的感知能力。文献[9]提出了一种 YOLOv8-PCB 缺陷检测模型，引入了 WIoUv3 损失函数，通过动态调整权重系数，降低了对低质量锚框的惩罚力度，提高了模型的收敛速度，并融合浅层尺度和小目标检测头提高了微小特征的捕捉能力，显著增强了模型对微小缺陷特征的捕获能力。这种模型设计充分利用了浅层网络的高分辨率特征信息，有效解决了传统方法在微小缺陷检测中存在的特征丢失问题，提高了缺陷检测的效果。文献[10]提出了一种废旧电路板表面缺陷分类模型，针对废旧电路板氧化腐蚀、划痕、裂痕等缺陷，将 ResNet34 架构与 Convolutional Block Attention Module（CBAM）注意力机制相结合，使得模型能够更有效地提取和利用多层次的特征信息。在特征提取过程中，CBAM 注意力机制引导网络将更多的计算资源分配给对分类任务贡献更大的特征区域，同时抑制无关背景信息的干扰。这种设计不仅增强了模型的特征表达能力，还提高了特征利用效率，使模型能够更准确地捕捉图像中的细微差异。文献[11]设计并实现了一套基于图像处理技术的电路板缺陷检测系统，该系统采用 FPGA 作为核心处理单元，实现了对电路板缺陷的高速、精准检测。针对电路板表面丝印标识对检测算法的干扰问题，提出了一种新的去除丝印算法，能够准确识别并去除电路板上的丝印文字和标识，同时保留关键的电路特征信息，减少了图像匹配的计算量，加快了模板匹配的检测速度，提高了检测精度。

综上所述，目前在电路板裸板走线和焊点质量缺陷检测领域，前人已经进行了大量深入的研究工作，在检测精度和稳定性方面取得了显著的成果，在电路板裸板检测领域展现出了巨大的应用潜力。然而，对于成品弱电板卡元器件的外观缺陷检测，现有的研究和应用仍然处于较为初级的阶段，在检测工业生产中返修板卡的表面缺陷方面还有一定的局限性。本文旨在研究弱电板卡器件层面的外观缺陷检测，以 YOLOv5s 算法为基础，融合了 CBAM 注意力机制和 Contextual Transformer Network（CotNet）模块，并引入了动态检测头来调整模型结构参数，提出了一种改进 YOLOv5s 表面缺陷检测模型，通过在实验室自行建立的故障板卡数据集上进行了实验验证，改进后的模型表现出不错的准确性和可靠性。

1 原始 YOLOv5s 模型

YOLO 作为当前计算机视觉领域中最流行的目标检测算法之一，凭借其优秀的检测精度和高效的检测效率，在学术界和工业界都得到了广泛应用[12]。与传统的目标检测算法相比，YOLO 的最大优势在于其创新的单阶段检测架构。传统方法如 R-CNN 系列算法通常采用两阶段检测流程，首先需要生成大量候选区域，然后对这些区域进行分类和边界框回归，这种分步处理的方式虽然能够获得较高的检测精度，但不可避免地带来了较大的计算开销和较慢的检测速度。而 YOLO 算法通过创新的网络设计，将目标检测任务转化为一个统一的回归问题，仅需对输入图像进行一次前向传播即可同时完成目标定位和分类任务，这种端到端的处理方式不仅大幅提升了检测速度，还保持了较高的检测精度。特别值得一提的是，YOLO 在进行目标检测时充分利用了整张图像的全局上下文信息，而不是像传统方法那样仅依赖局部区域信息，这种全局视角使得 YOLO 在检

测目标的准确性和一致性方面都有显著提升，尤其是在处理遮挡、变形等复杂场景时表现出更强的鲁棒性。

YOLOv5s 模型[13]的网络结构主要由 4 个关键模块组成：输入端（Input）、骨干网络（Backbone）、颈部网络（Neck）和头部网络（Head）。其网络结构如图 1 所示，首先，输入端负责对原始图像进行预处理，包括图像缩放和归一化等操作，为后续的特征提取做好准备。骨干网络采用 CSPDarknet53 结构，通过多级卷积和下采样操作，逐步提取图像的多层次特征，这些特征既包含底层的细节信息，也包含高层的语义信息。颈部网络则是对骨干网络提取的特征进行多尺度融合和增强，生成更加丰富和鲁棒的特征表示。最后，头部网络利用这些融合后的特征，结合改进的锚点机制，在多个尺度上进行边界框回归和类别预测，最终输出精确的目标检测结果。这种网络结构的设计不仅保证了检测精度，还通过模型轻量化设计确保了检测效率。

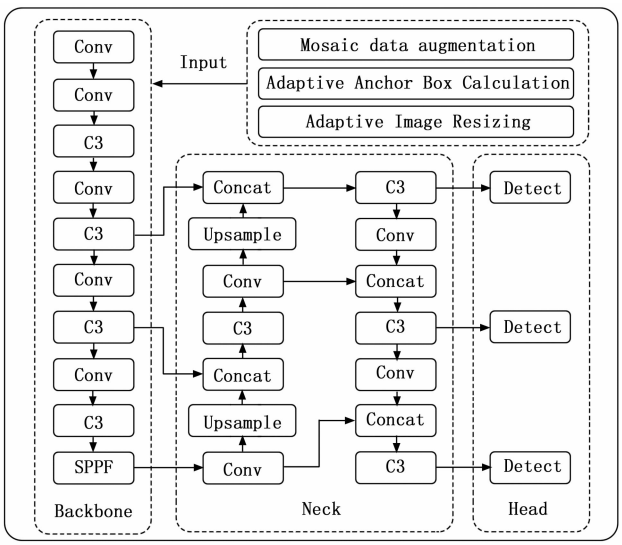

图 1　YOLOv5s 网络结构

2　改进 YOLOv5s 模型

2.1　CBAM 注意力机制

本研究是针对弱电板卡的表面缺陷检测，属于小目标检测的范畴，随着网络的逐渐加深，图片的纹理、轮廓等细节信息会丢失，因此，在骨干网络部分引入一个 CBAM 注意力机制[14]来增强板卡器件局部区域的细节特征，去除一些无关信息，进而提升检测的准确率，CBAM 注意力机制的结构如图 2 所示。

CBAM 属于混合域注意力机制，相比 Squeeze-and-Excitation（SE）注意力机制主要关注通道信息特征而言，CBAM 注意力机制通过综合通道和空间的注意力，能够在电路板元器件表面缺陷检测中有效增强关键特征的提取和区分，尤其对于分布集中、排列紧密的复杂背景下的小尺寸元器件表面缺陷检测具有更明显的优势。

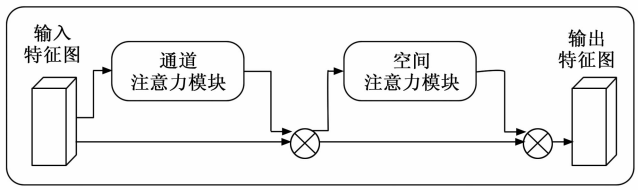

图 2　CBAM 注意力机制结构

通过强调特征图中的关键区域和通道信息，CBAM 能够提升了模型的敏感性和鲁棒性，从而提高表面缺陷检测的效率和准确性。

2.2　COTNET 模块

Contextual Transformer Network（CotNet）是一种用于增强深度神经网络特征提取能力的新型机制，CotNet 模块能够通过捕捉全局上下文信息来增强自注意力的能力，其核心思想是通过对比学习的方法，最大化相同类样本之间的相似性，同时将不同类样本之间的距离最小化，这一过程使得模型在特征学习时能够更好地区分图像的细微差异[15]。在电路板元器件缺陷检测中，CotNet 模块可以有效处理高噪声和模糊的图像数据。电路板上元器件的种类繁多，通过对比学习，CotNet 能够加强对器件正常特征和缺陷特征的识别，提升检测模型在面对相似特征时的准确性，结合 CBAM 注意力机制对于局部细节特征的增强，二者从全局和局部两个层面相互补充，进一步提升了模型在复杂场景下的检测性能。

CotNet 模块的结构如图 3 所示，输入的特征图通过 $k\times k$ 的卷积操作进行编码生成了一个保留了图像局部上下文信息静态特征的 $\boldsymbol{K}^1$ 矩阵。接下来，将局部信息与原始信息拼接后经过两次 1×1 的卷积计算得到注意力矩阵 $\boldsymbol{A}$[16]：

$$\boldsymbol{A}=[\boldsymbol{K}^1,Q]W_\theta W_\delta \tag{1}$$

其中：$\boldsymbol{A}$ 代表注意力矩阵，Q 是输入特征图的查询值，W_θ 和 W_δ 是两次卷积运算的结果，并且 W_θ 中包含 ReLU 激活函数，即 $F(x)=\max(0,x)$，W_δ 中不包含该函数。这一操作就使得注意力矩阵 $\boldsymbol{A}$ 中也包含了静态上下文信息。最后，将矩阵 $\boldsymbol{A}$ 与 $\boldsymbol{V}$ 点乘得到全局动态上下文信息特征 K^2：

$$\boldsymbol{K}^2=\boldsymbol{A}\otimes\boldsymbol{V} \tag{2}$$

其中：$\boldsymbol{V}$ 是输入特征图信息 X 与权值矩阵 $\boldsymbol{W}_v$ 的乘积，即 $\boldsymbol{V}=X\boldsymbol{W}_v$。最后，将 $\boldsymbol{K}^1$ 矩阵和 $\boldsymbol{K}^2$ 矩阵加权融合后就输出了 CotNet 的结果。

2.3　动态检测头

在电路板元器件表面缺陷检测中，图像局部区域的特征通常较为微弱，环境的光照、噪声及背景复杂度等因素会对检测效果造成较大影响。传统检测头可能无法有效提取关键信息，动态检测头（DyHead，Dynamic

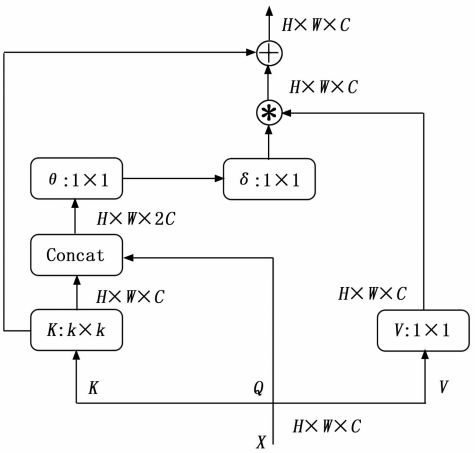

图 3 CotNet 结构

Head）通过动态调整模型结构和参数[17]，能够自适应地忽略背景噪声，聚焦于重要的小目标特征，在不同条件下生成精确的检测框，有效提高小目标检测的准确性和可靠性，其结构如图 4 所示。

动态检测头在特征张量的各个维度上提供尺度感知、空间感知和任务感知的注意力机制，每个注意力机制各自负责处理一个特定维度。假设检测层的三维特征张量为 $F\in R^{L\times S\times C}$，该注意力函数 $W(F)$ 计算公式如下所示[18]：

$$W(F)=\pi_C\{\pi_S[\pi_L(F)\cdot F]\cdot F\}\cdot F \tag{3}$$

其中：π_L、π_S、π_C 分别为尺度感知注意力函数、空间感知注意力函数、任务感知注意力函数。尺度感知注意力在层级维度动态调整权重，通过分析多尺度特征图中各层级对当前目标的贡献度，抑制无关尺度的噪声，强化小目标所在的高分辨率特征层，对电路板上的微小缺陷，自动增强浅层特征的细节信息。空间感知注意力在空间维度动态聚焦关键区域，识别元器件表面缺陷的潜在位置，抑制背景干扰，在复杂电路板背景下，突出焊点、引脚等关键区域的特征响应。任务感知注意力在通道维度动态分配任务权重，根据分类、定位等不同任务需求，选择性地增强相关特征通道。

在本模型的结构设计中，使用了一组 DyHead 模块来提升检测头的性能，从而提升算法对板卡元器件的检测效果，改进后的 YOLOv5s 完整网络结构如图 5 所示。

2.4 SIOU 损失函数

在 YOLOv5s 模型中，采用 CIou Loss 作为损失函数[19]，其参数示意图如图 6（a）所示，其计算公式如下：

$$L_{\mathrm{CIoU}}=1-\mathrm{IoU}+\frac{\rho^2(b,b^{gt})}{c^2}+\alpha v \tag{4}$$

其中：IoU 表示真实目标框与预测框的交并比；b 为预测框，b^{gt} 为真实目标框，ρ^2（b，b^{gt}）表示预测框

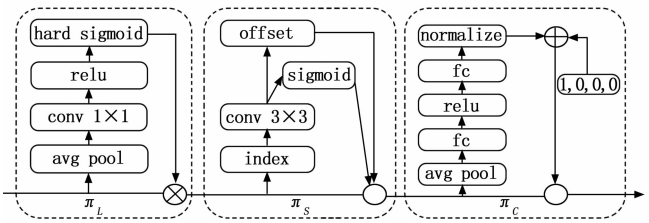

图 4 DyHead 结构

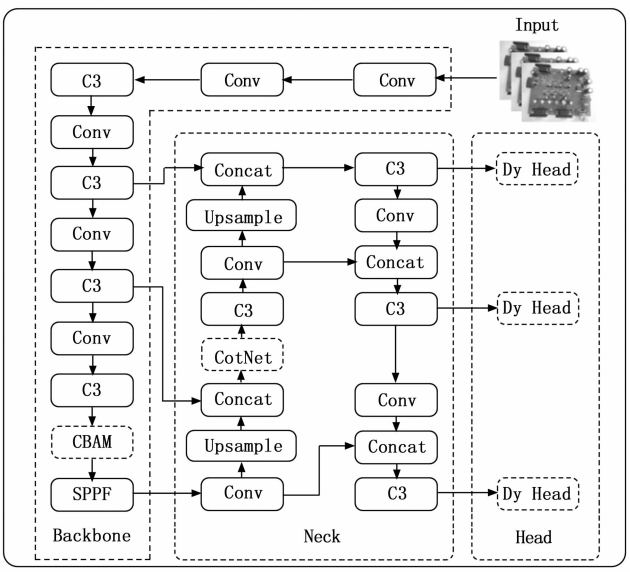

图 5 改进 YOLOv5s 网络结构

和真实目标框中心点之间的欧式距离；c 表示真实目标框的最小包围框与预测框最短对角线长度；α 是权重系数；v 是宽高比的特性。α 和 v 的计算公式如下[20]：

$$v=\frac{4}{\pi^2}\left(\arctan\frac{w^{gt}}{h^{gt}}-\arctan\frac{w}{h}\right)^2 \tag{5}$$

$$\alpha=\frac{v}{(1-\mathrm{IoU})+v} \tag{6}$$

其中：w 和 h 表示预测框的宽和高，w^{gt} 和 h^{gt} 表示真实目标框的宽和高。

CIoU 充分考虑了预测框与真实框之间的重叠面积、中心点距离以及宽高比，但其计算相对复杂，降低了模型的收敛速度，并且在预测框与真实目标框完全不重叠的情况下，无法有效反映它们之间的紧密关系。此外，相较于 GIoU 对非重叠区域的低效优化，DIoU 对方向不敏感的缺陷，SIoU 通过多维度几何联合优化，显著提升了复杂干扰下微小缺陷的定位鲁棒性，同时加速模型收敛，在密集元件、高噪声的电路板图像中实现更高准确率和更稳定的检测效果。因此，本模型中将 CIoU 替换为 SIoU 损失函数，其参数示意图如图 6（b）所示。

SIoU 损失函数由交并比损失、形状损失、角度损失和距离损失组成[21]，定义如下。

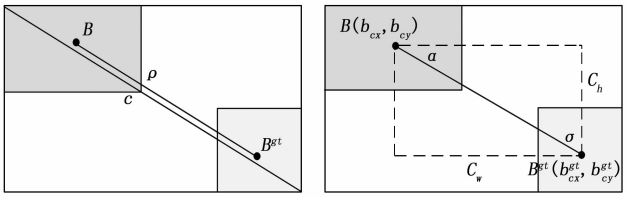

（a）CIoU参数示意图　　（b）SIoU参数示意图

图 6　损失函数参数示意图

角度损失 Λ 表示为：

$$\Lambda = 1 - 2\sin^2\left(\arcsin x - \frac{\pi}{4}\right) \tag{7}$$

其中：$x = C_h/\sigma = \sin\alpha$，$\sigma$ 为预测框和真实目标框中心点之间的距离，C_h 为预测框和真实目标框中心点之间的高度差，σ 和 C_h 用下式表示：

$$\sigma = \sqrt{(b_{cx}^{gt} - b_{cx})^2 + (b_{cy}^{gt} - b_{cy})^2} \tag{8}$$

$$C_h = \max(b_{cy}^{gt}, b_{cy}) - \min(b_{cy}^{gt}, b_{cy}) \tag{9}$$

其中：(b_{cx}, b_{cy}) 和 $(b_{cx}^{gt}, b_{cy}^{gt})$ 为预测框和真实目标框中心点的坐标。形状损失 Ω 表示为：

$$\Omega = \sum_{t=w,h}(1 - e^{-w_t})^{\theta} \tag{10}$$

其中：θ 为形状损失调节因子，w_w 和 w_h 为两个边界框宽度和高度的相对差异，用下式表示：

$$w_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})}, w_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})} \tag{11}$$

其中：w 和 w^{gt} 为预测框和真实目标框的宽度，h 和 h^{gt} 为预测框和真实目标框的宽度。距离损失 Δ 表示为：

$$\Delta = \sum_{t=x,y}(1 - e^{-\gamma\rho_t}) \tag{12}$$

其中：$\gamma = 2 - \Lambda$，ρ_x 和 ρ_y 表示赋予的权重，用下式表示：

$$\rho_x = \left(\frac{b_{cx}^{gt} - b_{cx}}{C_w}\right)^2, \rho_y = \left(\frac{b_{cy}^{gt} - b_{cy}}{C_h}\right)^2 \tag{13}$$

其中：C_w 为预测框和真实目标框中心点 x 坐标的差值，C_h 为预测框和真实目标框中心点 y 坐标的差值。则 SIoU 损失函数可表示为：

$$L_{SIoU} = 1 - IoU + \frac{\Delta + \Omega}{2} \tag{14}$$

3　实验设计与分析

3.1　实验环境

实验中硬件环境使用 4 K 超清摄像头，搭配 LED 灯组成图像采集单元，采集示意图如图 7 所示。实验在 Windows 10 操作系统下进行，CUDA 版本为 11.7，CPU 为 Intel Core i5-12 600 K，GPU 为 Nvidia RTX3090 Ti，24 GB 显存，网络训练基于深度学习框架 PyTorch1.13.0 实现，并使用 Python3.8.1 进行训练。

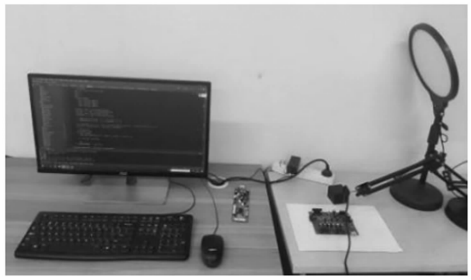

图 7　图像采集实验环境

3.2　数据集制作与预处理

以和谐号动车组列车内视频服务器的音视频解码板为例，由实验室人员自行构建实验数据集，解码板图片如图 8（a）所示。数据集包括 5 种板卡缺陷类型，分别是元件引脚误接（标签 0）、焊点焊接不良（标签 1）、元件引脚断裂（标签 2）、外部物质介入（标签 3）、元件外观损坏（标签 4），不同表面缺陷示例如图 8（b）～（f）所示。

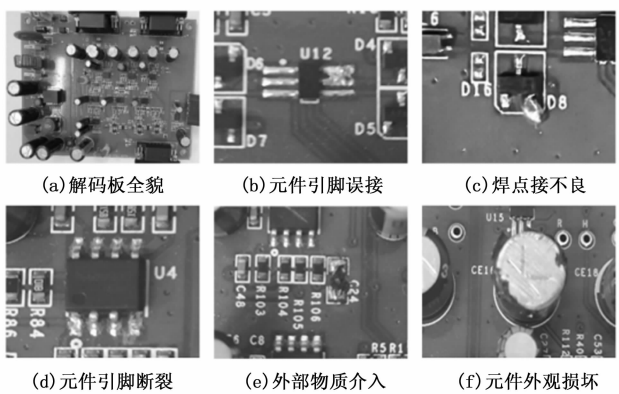

(a)解码板全貌　(b)元件引脚误接　(c)焊点接不良

(d)元件引脚断裂　(e)外部物质介入　(f)元件外观损坏

图 8　解码板及表面缺陷类型图像

数据采集过程中，共获取原始图像 3 400 张。每张图片上分布有一个或多个缺陷种类，经统计，原始图像中包含元件引脚误接缺陷 1 200 个，焊点焊接不良缺陷 1 350 个，元件引脚断裂缺陷 1 420 个，外部物质介入缺陷 1 105 个，元件外观损坏缺陷 1 380 个。针对初始数据分布不均衡问题，对数据集采取了定向增强手段，包括随机旋转（±30°）、平移（20%偏移）、噪声注入、图片翻转、局部裁剪、遮挡（最大遮挡面积 30%）与光照变换（亮度调整±40%），最终使各类缺陷样本量维持在 2 000 个以上，具体缺陷数量为 2 030 个标签 0，2 080 个标签 1，2 120 个标签 2，2 010 个标签 3，2 100 个标签 4。

数据集标注时，按照以下步骤操作：①打开图片：在 LabelImg 工具中选择并打开待标记的电路板缺陷图片。②绘制标注框：使用工具中的矩形框功能，框选图片中的缺陷区域。③分配标签：为每个标注框分配对应

的缺陷类型标签。④保存标注：标注完成后，将文件保存为 XML 格式或 YOLO 格式的 TXT 文件。⑤重复此操作，直到所有缺陷图片都标注完成。⑥将标签和图像数据按照 8：2 的比例分为训练集和验证集。其中训练集每类样本 1 608～1 696 张，验证集 402～424 张，总计训练集 8 272 张、验证集 2 068 张。

3.3 模型训练

本节基于包含五类缺陷的综合数据集展开模型训练，数据集中的单张图像可能同时存在多个缺陷，模型需并行完成多标签分类与定位任务。模型各项训练参数如表 1 所示，经过改进后的模型训练结果如图 9 所示，分别是模型训练的准确率、召回率、mAP_{50} 值和 $mAP_{50:95}$ 值。可以看出，模型的训练过程平稳，在多个评估指标上展现出良好的性能。

表 1 训练参数

项目	参数
训练轮数	100
Batch Size	16
图片输入	640×640
初始学习率	0.01
权重衰减系数	0.000 5
预热轮数	3
动量系数	0.937

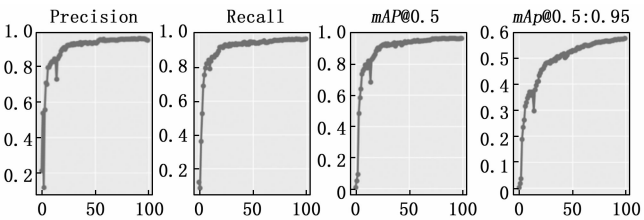

图 9 改进后模型训练结果

3.4 模型评价指标

实验采用准确率（P，precision）、召回率（R，recall）、平均精确度（AP，average precision）、平均精确度均值（mAP，mean average precision）[22-23] 作为评价指标。

准确率是指模型预测为正类的样本中，真正为正类的比例，由下式定义：

$$P = \frac{TP}{TP + FP} \tag{15}$$

召回率是指所有实际为正类的样本中，被模型正确预测为正类的比例。具体定义为：

$$R = \frac{TP}{TP + FN} \tag{16}$$

其中：TP 表示模型正确预测为正类的样本数；FP 表示模型错误地将负类预测为正类的样本数；FN 表示模型错误地将正类预测为负类的样本。

平均精确度 AP 是在多个不同召回率点上计算的准确率的平均值。可以理解为一个曲线下的面积，该曲线由不同置信度阈值下的 Precision-Recall 曲线构成。平均精确度均值 mAP 则是所有类别的 AP 的均值[24]。其计算方法为：

$$AP = \int_0^1 P(R)\mathrm{d}R \tag{17}$$

$$mAP = \frac{1}{C}\sum_{i=1}^{C} AP_i \tag{18}$$

其中：C 是类别的总数；i 表示第 i 个类别。

mAP_{50} 指的是在置信度阈值为 0.5 时所有类别的平均精确度；$mAP_{50:95}$ 代表置信度阈值为 0.5～0.95 、步长为 0.05 时的整体平均精确度。

3.5 实验结果分析

3.5.1 损失函数对比实验

本文验证了改进模型分别在 CIoU、DIoU、GIoU 和 SIoU 损失函数作用下的图像检测效果，保证实验参数设置和模型结构一致的情况下，使用实验室自制数据集进行了实验对比，对比结果如表 2 所示。

表 2 各类损失函数对比试验

损失函数	mAP_{50}/%	$mAP_{50:95}$/%
CIoU	95.3	56.2
DIoU	95.5	56.4
GIoU	95.8	56.7
SIoU	96.5	57.1

可以看出，使用几类损失函数都表现出了不错的检测效果，但相比来说，在 SIoU 损失函数的作用下，模型对小目标检测更有优势，GIoU 通过引入最小包围框扩展 IoU 计算，缓解了无重叠目标（IoU＝0）的梯度消失问题，但对中心点对齐和宽高比优化不足，导致复杂背景下易受噪声干扰。DIoU 在 IoU 基础上增加中心点距离惩罚项，强化了中心点对齐能力，但对目标旋转和宽高比变化敏感，难以精准拟合细长型缺陷，比如元件裂纹等。CIoU 在 DIoU 基础上引入宽高比一致性约束，通过强制宽高比匹配提升检测框形状精度，但固定权重策略易抑制小目标优化。

相较于这 3 类损失函数，SIoU 通过角度、距离和形状 3 种机制联合优化，利用角度损失 Λ 校正预测框倾斜，并通过距离损失△分解 x/y 方向的距离惩罚，减少优化冲突，形状损失 Ω 则自适应调整宽高比惩罚强度，显著提升了小目标敏感度。

实验结果表明，SIoU 在电路板缺陷检测任务中 mAP_{50} 达到了 96.5%，较 CIoU、DIoU、GIoU 分别提升 1.2%、1.0%、0.7%，$mAP_{50:95}$ 提升至 57.1%，高于其他损失函数 0.4%～0.9%。此外，使用 SIoU 损失函数的训练过程中收敛速度也相对更快。这一结果表

明，采用 SIoU 损失函数有助于减少小目标的漏检率，提高了检测准确度，为实际应用中的目标检测系统提供了更高的可靠性和精确性保障。

3.5.2　消融实验

为了探究 CBAM 注意力机制、CotNet 模块改进、动态检测头以及 SIoU 损失函数对于模型识别能力的影响，在实验室构建的数据集验证集上进行了消融实验，以 YOLOv5s 为基础，逐步引入各模块，验证各模块对整个模型的改进效果，其结果如表 3 所示。

表 3　算法改进在验证集上的消融实验结果

序号	算法	Precision /%	Recall /%	mAP_{50} /%	$mAP_{50:95}$ /%
1	YOLOv5s	90.9	91.7	92.2	54.6
2	YOLOv5s＋CBAM	91.8	92.8	93.8	55.5
3	YOLOv5s＋CotNet	92.3	93.3	94.1	55.7
4	YOLOv5s＋动态检测头	91.5	92.7	93.7	55.2
5	YOLOv5s＋SIoU	91.9	91.9	93.5	55.4
6	YOLOv5s＋CBAM＋CotNet	93.5	95.4	94.7	56.2
7	YOLOv5s＋CotNet＋动态检测头	93.3	95.2	94.8	56.5
8	YOLOv5s＋CBAM＋CotNet＋动态检测头	94.3	96.2	95.7	56.6
9	YOLOv5s＋CotNet＋动态检测头＋SIoU	94.9	95.8	95.9	56.9
10	YOLOv5s＋CBAM＋CotNet＋动态检测头＋SIoU	95.7	96.9	96.5	57.1

实验表明，在原始算法基础上单独加入各个改进模块都会提升算法的识别效果，尤其是引入 CotNet 模块后对算法的性能提升最大，$mAP_{50:95}$ 指标提升了 1.1%，原因是 CotNet 模块通过建立缺陷区域与周围元器件的上下文关联，显著增强密集引脚间的特征表达能力；CBAM 通过双路注意力机制分别从通道维度筛选关键语义特征与空间维度聚焦局部异常区域，有效抑制焊点反光等背景干扰，单独使用时 $mAP_{50:95}$ 指标提升了 0.9%；动态检测头的引入使得模型能够在不同尺度的目标中自适应调整检测器，使其更好地适应目标大小的变化，这一改进有效提升了对小目标的检测，$mAP_{50:95}$ 指标提升了 0.6%；SIoU 损失函数通过将角度、距离和形状 3 种机制联合优化，将小目标定位能力大大提升，最终 $mAP_{50:95}$ 指标提升了 0.8%。

另外，模块间的协同效应进一步放大了性能增益，CBAM 与 CotNet 组合实现了局部聚焦与全局上下文分析的优势互补，使 $mAP_{50:95}$ 提高了 1.6%，当进一步联合动态检测头与 SIoU 使用时，前者提供的多尺度感知能力与后者的精细化定位约束形成正向耦合，推动小目标检测精度突破性提升，模型呈现出清晰的层级优化链路：CBAM 率先过滤背景噪声，CotNet 强化缺陷特征关联，动态检测头适配目标尺度变化，SIoU 最终精修检测框位置，四者协同使得算法的识别效果提升到了最大，$mAP_{50:95}$ 相较于未改进之前提升了 2.5%，准确率提升了 4.8%，召回率提升了 5.2%，mAP_{50} 提升了 4.3%，实验表明通过模块化的改进方案明显增强了 YOLOv5s 在电路板元器件表面缺陷检测任务中的表现，不仅提升了检测精度，还提高了模型的鲁棒性，证明了本研究改进的有效性。

3.5.3　对比试验

图 10 展示了改进后的算法模型对试验板卡的实际检测效果，该板卡上包含 5 种类型共 7 个缺陷，使用改进后的模型对其进行检测，可以看到，7 个缺陷均被检测出来，且缺陷位置和缺陷分类均准确无误。

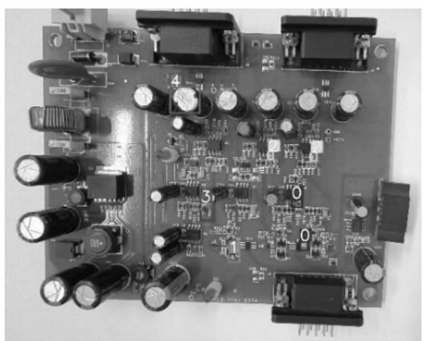

图 10　改进后算法模型检测效果

如表 4 所示，在实验数据集和实验环境、实验参数不变的条件下，将目前一些目标检测算法 Faster RCNN[25]、SSD[26]、YOLOv3[27]、YOLOv5s[13]与本文改进的模型进行了纵向对比，可以看出，本文模型的各项指标均优于其他几个模型，特别是准确率和召回率方面分别达到了 95.7% 和 96.9%，相较于 SSD 分别提升了 10.4% 和 10.8%，本模型的 mAP_{50} 指标达到了 96.5%，相比其他几种模型提高了 4.3～9.0%，在更为严格的 $mAP_{50:95}$ 指标上，相比其他几种模型提高了 2.5～8.4%，这些提升说明改进后的模型在检测板卡元器件

表 4　改进模型与其他模型检测性能比较

序号	算法	Precision/%	Recall /%	mAP_{50} /%	$mAP_{50:95}$ /%	FLOPS	FPS /帧
1	Faster RCNN	88.9	89.5	91.0	52.3	104.5×10^9	21.6
2	SSD	85.3	86.1	87.5	48.7	63.3×10^9	36.8
3	YOLOv4	89.6	87.2	89.5	50.7	89.7×10^9	47.2
4	YOLOv5s	90.9	91.7	92.2	54.6	19.8×10^9	51.6
5	YOLOv5s ＋ PSA ＋ BiFPN ＋ P2 检测头＋EIoU	94.2	96.4	95.7	56.7	18.7×10^9	55.8
6	本文	95.7	96.9	96.5	57.1	17.3×10^9	58.3

表面缺陷时能够更精确地定位和分类，大大降低了模型错检和漏检的概率。

另外，还将本文改进的模型与文献［28］中另一 YOLOv5s 改进算法（YOLOv5s＋PSA＋BiFPN＋P2 检测头＋EIoU）模型进行了横向对比，可以看出，该算法虽然整体优于原 YOLOv5s 算法，但 EIoU 对宽高比的刚性约束在处理倾斜类的缺陷时表现不佳，如引脚倾斜断裂、焊点偏移等，并且缺乏全局上下文关联，多缺陷共存场景下误检率较高，导致该算法在自建实验数据集上整体检测精度略低于本文改进算法，另外，本文改进算法利用动态检测头减少了冗余计算，结合 CBAM 轻量化的特性，使得算法可以执行的每秒浮点运算次数为 17.3×10^9，相比文献［28］的方法减少了 1.4×10^9，相比原 YOLOv5s 算法减少了 2.5×10^9，这说明改进后的算法在保持高准确率的同时，减少了计算开销，显著提升了算法的能效比，优化了资源利用，降低了算法的计算复杂度，使其在相同的计算资源下能够更加高效地运行。同时，改进后的算法 FPS 达到了 58.3，实时检测效率相比其他算法也有一定提升，相比原 YOLOv5s 算法增加了 6.7，这意味着改进后的算法能够在更短的时间内处理更多的图像帧，降低了图像处理的延迟，从而提高了整个模型的实时性能和稳定性。

然而，该改进模型也存在一定局限性，由于改进主要针对和谐号动车组列车内视频服务器的音视频解码板展开的缺陷研究，属于实验室自制的板卡数据集，目前还未在其他公开板卡数据集上展开验证，在其他的工业生产环境中，板卡的类型、材质、生产工艺等因素可能更为复杂多样，数据集的局限性可能导致模型在一些特殊工艺生产的板卡或未在数据集中充分体现的缺陷类型上检测效果不佳。

4 结束语

本文提出了一种基于改进 YOLOv5s 的弱电板卡表面缺陷检测方法，对动车组列车音视频解码板器件表面的缺陷类型进行了研究，针对板卡器件数量多、分布密集的问题，引入了 CBAM 注意力机制，提升了模型对重要特征的聚焦能力；针对板卡器件尺寸小、细节特征易被忽视的问题，融合了 CotNet 模块，增强了对全局信息的利用能力；为了提升模型的自适应性能和目标框定位精度，引入了动态检测头和 SIoU 损失函数，前者通过自适应调整检测头参数可以更好地适应不同尺寸和形状的目标，后者则通过更精确地度量预测框与真实框之间的相似度，提高了模型的自适应性和目标框回归的精确度。

实验结果表明，改进后的算法准确率达到了 95.7%，相比原 YOLOv5s 算法提升了 4.8%，并且在保持高准确率的同时，降低了算法的计算复杂度，优化了资源利用率。此外，其他各项指标也都有所提升，召回率、mAP_{50} 和 $mAP_{50:95}$ 分别提升了 5.2%、4.3% 和 2.5%，并且模型在实时检测效率上也有不错的表现。这些提升表明，改进的算法在弱电板卡的器件表面缺陷检测方面表现出了更强的识别能力和稳定性，但由于本研究的板卡数据集较少，类型较为单一，各类缺陷的归纳还不够全面，模型在处理更多样化和复杂的场景时可能会面临挑战，未来将进一步扩充板卡数据集，引入更多不同类型和不同缺陷模式的样本，以增强模型的泛化能力，并且还将针对模型的运行效率和实时性继续改进，使模型具有更快的检测速度和更高的检测精度。

参考文献：

[1] LING Q, ISA N A M. Printed circuit board defect detection methods based on image processing, machine learning and deep learning: A survey [J]. IEEE Access, 2023, 11: 15921－15944.

[2] 王升琦. 基于微小目标检测的印刷电路板故障诊断研究 [D]. 大连：大连交通大学，2022.

[3] 马春斌，黄 文，李宗泽. 基于多种图像的电路板故障诊断系统研究 [J]. 计算机测量与控制，2022，30 (3)：15－18.

[4] MALLAIYAN SATHIASEELAN M A, PARADIS O P, TAHERI S, et al. Why is deep learning challenging for printed circuit board (pcb) component recognition and how can we address it? [J]. Cryptography, 2021, 5 (1): 9.

[5] 谢 黎，袁小芳，尹柏鑫. 基于改进 YOLOv4 网络的电路板元器件缺陷检测 [J]. 测控技术，2022，41 (4)：19－27.

[6] 王 千，王 成，冯振元，等. K-means 聚类算法研究综述 [J]. 电子设计工程，2012，20 (7)：21－24.

[7] 王淑青，张子言，朱文鑫，等. 基于改进 YOLOv5 的 PCB 板表面缺陷检测 [J]. 仪表技术与传感器，2023，(5)：106－111.

[8] 陈锦妮，拜晓桦，李云红，等. 基于 PA-YOLOv5 的印制电路板缺陷检测 [J]. 红外技术，2024，46 (6)：654－662.

[9] 王 艳，罗 健，陶 金，等. 基于 YOLOv8-PCB 的印制电路板缺陷检测 [J/OL]. 激光与光电子学进展，2024：1－18. [2025－02－22]. http://kns.cnki.net/kcms/detail/31.1690.TN.20240624.2254.060.html.

[10] 余光海，盛光鸣，张元昊，等. 基于深度学习的废旧电路板表面缺陷分类 [J]. 现代计算机，2024，30 (10)：17－22.

[11] 张立国，雷璇瑞，金 梅，等. 基于图像处理的电路板缺陷检测系统设计 [J]. 高技术通讯，2024，34 (2)：209－217.

[12] 张新航，张雅茹，麻振华，等. 基于深度学习方法的 YOLO 目标检测综述 [J]. 长江信息通信，2024，37 (8)：52－56.

[13] 王　涛，黄　丹，刘禅奕，等. 基于 YOLOv5s 的无人机图像车辆检测 [J]. 计算机与现代化，2024，(8)：108－113.

[14] XU H，WANG L，CHEN F. Advancements in electric vehicle PCB inspection：Application of Multi-Scale CBAM，Partial Convolution，and NWD Loss in YOLOv5. World Electric Vehicle Journal. 2024；15 (1)：15.

[15] HUANG H，LU Y，ZHOU S，et al. CoTNeT：Contextual transformer network for encrypted traffic classification [J]. Egyptian Informatics Journal，2024，26：100475.

[16] 黄　昊，李海涛. 基于 CotNet 改进 YOLOv5 的接地线目标检测 [J]. 计算机系统应用，2023，32 (5)：283－290.

[17] WANG J，LI Y，WANG J，et al. An underwater dense small object detection model based on YOLOv5-CFDSDSE [J]. Electronics，2023，12 (15)：3231.

[18] 吴明杰，云利军，陈载清，等. 改进 YOLOv5s 的无人机视角下小目标检测算法 [J]. 计算机工程与应用，2024，60 (2)：191－199.

[19] XUE J，CHENG F，LI Y，et al. Detection of farmland obstacles based on an improved YOLOv5s algorithm by using CIoU and anchor box scale clustering [J]. Sensors，2022，22 (5)：1790.

[20] 李红伯. 基于改进 YOLOv5 的水上目标检测算法研究 [D]. 镇江：江苏科技大学，2023：43－45.

[21] GEVORGYAN Z. SIoU loss：More powerful learning for bounding box regression [J]. ArXiv Preprint ArXiv：2205.12740，2022：1－12.

[22] ZHANG M，YIN L. Solar cell surface defect detection based on improved YOLO v5 [J]. IEEE Access，2022，10：80804－80815.

[23] ZHANG Y，YU C，LIU H，et al. An integrated goat head detection and automatic counting method based on deep learning [J]. Animals，2022，12 (14)：1810.

[24] 李　杰，王　峰，马　晨，等. 基于改进 YOLOv5s 的无人机图像识别 [J]. 电光与控制，2024，31 (4)：22－27.

[25] WANG H，Xiao N. Underwater object detection method based on improved faster RCNN [J]. Applied Sciences，2023，13 (4)：2746.

[26] DING F，ZHUANG Z，LIU Y，et al. Detecting defects on solid wood panels based on an improved SSD algorithm [J]. Sensors，2020，20 (18)：5315.

[27] LI J，GU J，HUANG Z，et al. Application research of improved YOLO V3 algorithm in PCB electronic component detection [J]. Applied Sciences，2019，9 (18)：3750.

[28] 赵奕翔，苏检德，何富运，等. 改进 YOLOv5s 算法的 PCB 缺陷检测方法 [J/OL]. 无线电工程，2025：1－12 [2025－02－24]. http://kns.cnki.net/kcms/detail/13.1097.TN.20250107.0937.002.html.

(上接第 80 页)

[7] 赵　祥，蒙建国，曲丹萍，等. 马铃薯挖掘机摆动筛振动测试与分析 [J]. 农机化研究，2023，45 (10)：171－176.

[8] 刘俊利，缪炳荣，张　盈，等. 基于 Morlet 小波与 CART 决策树的滚动轴承故障诊断方法 [J]. 机械强度，2024，46 (1)：1－8.

[9] 刘　旻，邹小林. 基于 VMD 与包络谱分析的水力机械振动故障特性研究 [J]. 中国农村水利水电，2023 (12)：280－288.

[10] 王　健，邬　娜，杨建伟，等. 基于改进 DANN 和注意力机制的轴箱故障诊断方法 [J]. 机床与液压，2024，52 (16)：194－199.

[11] 史先传，张本阳，卢鸿运，等. 基于 Modbus RTU 协议的多传感器数据采集系统设计 [J]. 仪表技术与传感器，2024 (7)：46－50.

[12] 王　桥，彭显锋，余选程，等. RS232 串口转手机蓝牙通讯在自动气象站维修维护中的应用研究 [J]. 中国设备工程，2024 (8)：82－84.

[13] 陶忠明，王　磊，魏鹏飞，等. 一种通用型多通道高码速率机载 RS422 总线信号采集板设计 [J]. 长江信息通信，2023，36 (9)：112－115.

[14] 任瑶瑶，马金平. 基于 RS485 的多主机对等通信系统的设计与实现 [J]. 山东大学学报：工学版，2023，53 (5)：156－164.

[15] 周付明，刘武强，杨小强，等. 基于精细化改进多尺度快速样本熵的旋转机械故障诊断方法研究 [J]. 机械强度，2023，45 (1)：1－8.

[16] 丁嘉凯，王　义，穆志国，等. 基于多缩放基调频变换的时频脊线精细化表征方法 [J]. 振动与冲击，2023，42 (19)：22－29.

[17] 万书亭，贾东亮，孙瑞滨，等. 基于振动信号频域离散特征的螺栓完全松动检测方法研究 [J]. 中国工程机械学报，2024，22 (2)：247－251.

[18] 张志成. 面向无标签数据的旋转机械故障诊断方法研究 [J]. 吉林大学学报：工学版，2022，52 (11)：2514－2522.

[19] 周　雅，栗心怡，武喜艳，等. 基于 DT-LIF 神经元与 SSD 的脉冲神经网络目标检测方法 [J]. 电子与信息学报，2023，45 (8)：2722－2730.

[20] 张祎晨，何　干，杜　凯，等. 基于精细神经元的类脑感知学习模型 [J]. 软件学报，2024，35 (3)：1403－1417.