

基于改进 YOLOv11 的太阳能电池板缺陷检测^{*}

包广斌 范超林 罗瞳 阚洪丽

(兰州理工大学计算机与通信学院 兰州 730050)

摘要: 针对现阶段太阳能电池板缺陷检测方法精度低、速度慢的问题,提出了一种基于改进 YOLOv11 的缺陷检测算法。首先,在骨干网络中引入 SimSPPF 模块,优化了特征提取过程。此外,采用 Slide Loss 损失函数提升了模型对困难样本的关注度。同时,在 C2PSA 中引入 LSKA 注意力机制,利用分离卷积核增强特征提取能力,并应用 Mish 激活函数增强网络非线性。最后,引入 Strip Pooling 策略,提高了模型对目标形状和分布变化的适应性。实验结果显示,改进算法 Persion 达到 86.8%,较原始算法提高 3.3%,mAP@0.5 达到 90.1%,较原始算法提高 2.6%,检测速度达到 149.254 fps,满足工业生产中太阳能电池板缺陷检测高精度、高效率的要求。

关键词: YOLOv11; 目标检测; 深度学习; 注意力机制; 太阳能电池板

中图分类号: TP391.4; TN247 文献标识码: A 国家标准学科分类代码: 520.20

Solar panel defect detection based on improved YOLOv11

Bao Guangbin Fan Chaolin Luo Tong Kan Hongli

(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: In order to solve the problems of low accuracy and slow speed of the current solar panel defect detection method, a defect detection algorithm based on improved YOLOv11 was proposed. Firstly, the SimSPPF module is introduced into the backbone network to optimize the feature extraction process. In addition, the Slide Loss function is used to improve the attention of the model to difficult samples. At the same time, the LSKA attention mechanism is introduced into C2PSA, the split convolutional kernel is used to enhance the feature extraction ability, and the Mish activation function is used to enhance the network nonlinearity. Finally, the Strip Pooling strategy was introduced to improve the adaptability of the model to the changes of target shape and distribution. The experimental results show that the improved algorithm Persion reaches 86.8%, which is 3.3% higher than the original algorithm, mAP@0.5 reached 90.1%, an increase of 2.6% compared with the original algorithm. The detection speed reaches 149.254 fps, which meets the requirements of high precision and high efficiency of solar panel defect detection in industrial production.

Keywords: YOLOv11; object detection; deep learning; attention mechanisms; solar panel

0 引言

近年来,能源问题日益严峻。太阳能因其成本低、可再生、无污染等特性,受到人们的广泛青睐^[1]。然而,太阳能电池板在使用过程中会产生划痕、脏污等缺陷,进而影响发电效率、减少使用寿命,甚至引发一系列的安全问题^[2]。因此,设计太阳能电池板缺陷检测算法具有重要意义。

传统的太阳能电池板缺陷检测方法依赖人工检查,检测效率低、准确性差^[3]。传统的计算机视觉技术虽然能够实现太阳能电池板缺陷检测,但检测效果差、检测速度慢,

难以满足工业需求^[4]。

随着深度学习技术的不断发展,许多学者提出了基于深度学习的太阳能电池板缺陷检测方法。Meng 等^[5]提出了一种基于“你只看一次”(you only look once, YOLO)的太阳能电池板缺陷检测算法。该算法削弱了主干提取深层信息的能力,减少了模型计算量,实现了准确高效地检测。Li 等^[6]提出了一种基于幽灵卷积以及小目标预测头的太阳能电池板缺陷检测方法,减轻了微小缺陷信息遗漏的情况,提高了模型推理速度。张猛等^[7]提出了一种基于 SimAM-Ada YOLOv5 的太阳能电池缺陷检测方法,在引

入可变形卷积的同时,将 Ada 池化融入空间金字塔池化(spatial pyramid pooling, SPP)模块,增加了缺陷信息的保留程度,并且引入了简单无参的注意机制,进一步优化了模型的特征提取能力,提高了算法的准确性和检测速度。

虽然深度学习技术提高了太阳能电池板缺陷检测的效果,但现有方法在处理划痕、断栅等微小缺陷时,检测精度往往不足。同时,还存在处理长距离依赖关系和复杂背景时检测效果较差、应对目标形状和分布变化时鲁棒性差等问题,难以满足工业需求。

针对上述问题,YOLOv11^[8]作为一种先进的目标检测算法,凭借高精度、高速度以及良好的适应性,为太阳能电池板缺陷检测提供了新的解决方案。该模型于 2024 年 9 月 30 日发布,作为 YOLO 系列的新兴算法,目前太阳能电池板缺陷检测领域尚无针对 YOLOv11 的改进研究。

尽管 YOLOv11 具备良好的性能,但应用于太阳能电池板缺陷检测领域时,模型仍存在对困难样本的关注度不足、上下文信息的捕捉能力有限、特征提取能力有待提升等问题。基于此,本文提出了一种基于改进 YOLOv11 的太阳能电池板缺陷检测算法。通过引入滑动损失(Slide Loss)函数、采用大可分离核注意力(large separable kernel attention, LSKA)、引入简单快速空间金字塔池化(simplified spatial pyramid pooling fast, SimSPPF)等改进

措施,优化了模型特征提取过程,提高了模型对目标形状和分布变化的适应性。经过一系列的消融实验与对比实验,结果显示,改进后算法提高了太阳能电池板缺陷检测时的精度和效率,满足了工业生产中高效率、高精度的检测需求,为太阳能电池板缺陷检测提供了一种更为高效和可靠的解决方案。

1 YOLOv11 算法模型

YOLOv11 是目标检测领域的一种优秀算法,相较于以往的 YOLO 系列模型,YOLOv11 实现了精度和速度的显著提升^[9],为目标检测领域带来了强大而高效的解决方案。

该模型由 Backbone、Neck 和 Head 三部分构成,网络结构如图 1 所示。Backbone 部分包含 Conv、C3k2、快速空间金字塔池化(spatial pyramid pooling fast, SPPF)及 C2PSA 等模块。C3k2 模块继承自 YOLOv8 中的 C2F 结构,外层结构与 C2F 相似,但其中的特征提取层由原本的 Bottleneck 层替换为 C3K 层。C2PSA 模块是 YOLOv11 网络中新增的注意力模块,位于 Backbone 的末尾部分,通过对特征图进行金字塔式的拆分和注意力加权,使模型更加关注图像关键区域,抑制了无关信息的干扰,提高了模型的准确性和鲁棒性。

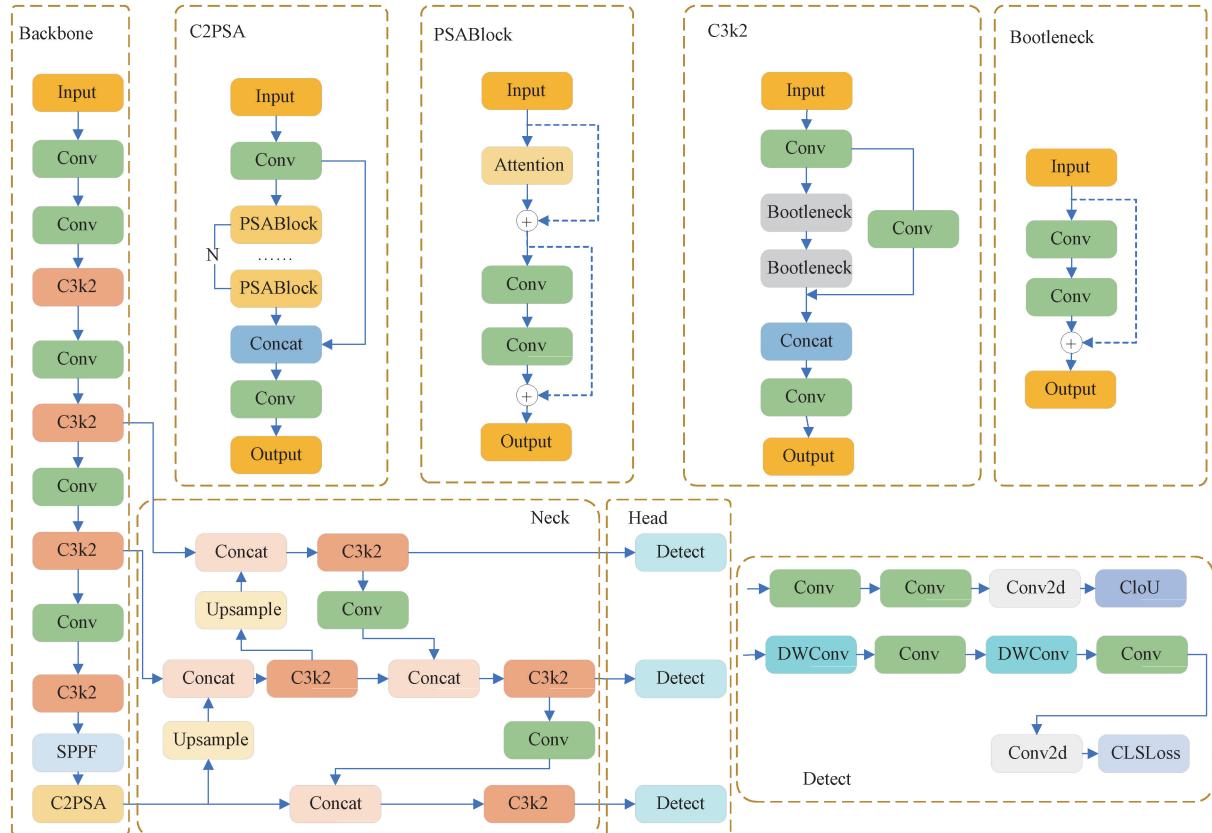


图 1 YOLOv11 网络结构
Fig. 1 YOLOv11 network structure

Neck 部分同样使用 C3k2 模块取代 C2F 结构。通过使用更高效的特征融合策略,充分结合不同尺度的特征信息,提升了模型对不同尺寸目标的检测能力。Head 部分使用解耦的分类头和回归头,实现类别特征和位置特征的解耦,提高了模型的检测效率。其中回归头使用正常的卷积操作预测边界框的位置信息,而分类头则运用深度可分离卷积(depth-wise separable convolution, DWConv)来减少模型的参数量和计算量,从而保证在提高检测精度的同时加快模型的推理速度。

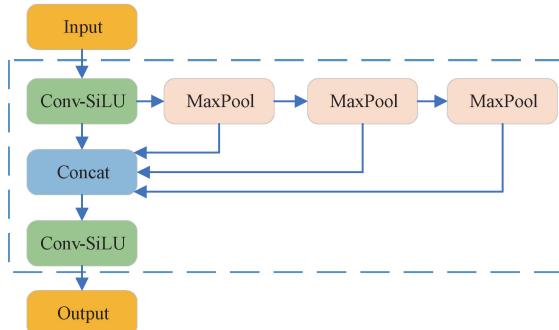
虽然 YOLOv11 算法在广泛的数据集应用中表现出色,但在识别太阳能电池板划痕、断栅此类细微瑕疵时,其性能仍有待提高。因此,本研究采用 YOLOv11 作为基础模型,并在此基础上采取了一系列的改进与优化措施,提出了一种更符合太阳能电池板缺陷检测要求的算法模型。

2 改进 YOLOv11 网络模型

2.1 改进快速空间金字塔池化

YOLOv11 网络中采用 SPPF 模块来增强特征提取能力,但快速空间金字塔池化存在计算冗余和效率不高的问题。因此,在骨干网络中引入 SimSPPF^[10]模块,以减少模型的计算量、提高运算效率、优化特征提取过程。

SimSPPF 主要由卷积操作和池化操作组成。首先,对



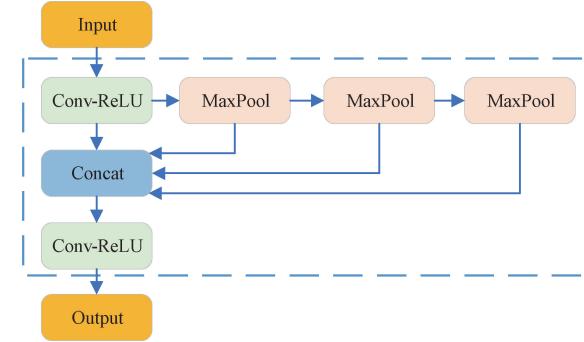
(a) SPPF module structure

输入特征图进行卷积运算,提取出图片中的关键特征。然后执行多次最大池化操作,拼接池化后的特征信息,有效地实现了不同尺度特征信息的融合。最后执行卷积操作,输出为指定通道数的特征信息。

SPPF 与 SimSPPF 模块结构如图 2(a)、(b)所示,与 YOLOv11 网络中采用的 SPPF 模块相比,SimSPPF 模块中的卷积运算采用线性整流函数(rectified linear unit, ReLU)来取代原有的 Sigmoid 线性单元^[11](sigmoid gated linear unit, SiLU),提高了模型的非线性和表达能力。改进算法通过在骨干网络上引入 SimSPPF 模块,降低模型复杂度,减少计算资源消耗,提高了特征提取的效率和准确性,有助于更快、更准确地检测太阳能电池板缺陷。

2.2 改进损失函数

在目标检测领域,容易样本的数量通常非常大,而困难样本则相对稀疏。简单样本通常较容易分类和定位,而困难样本则可能包含更多的噪声、遮挡或形变等因素,包含更多的关键信息,对模型的性能提升至关重要。然而, YOLOv11 网络模型中使用的二元交叉熵损失(binary cross entropy with logits loss, BCEWithLogitsLoss)函数在处理此类问题时更集中的预测简单样本,而忽略了对困难样本的预测。为解决该问题,在模型中引入 Slide Loss^[12]损失函数。



(b) SimSPPF module structure

图 2 SPPF 与 SimSPPF 结构对比图

Fig. 2 Comparison of SPPF and SimSPPF structures

Slide Loss 函数依据预测框与真实框之间的交并比(intersection over union, IoU)大小来区分简单样本与复杂样本。同时,为了精简超参数设置,该函数采用所有边界框 IoU 值的平均值作为阈值 μ 。其中 IoU 值低于 μ 的被视为负样本,高于 μ 的则视为正样本。但位于阈值边界附近的样本因分类模糊性,往往面临较大的损失。为了使模型能够更加关注边界样本,充分利用边界样本来训练网络,首先根据参数 μ 将样本划分为正样本与负样本,随后通过引入 Slide 加权函数来增强对边界样本的关注与利用。Slide 加权函数表达式如式(1)所示。

$$f(x) = \begin{cases} 1, & x \leq \mu - 0.1 \\ e^{1-\mu}, & \mu - 0.1 < x < \mu \\ e^{1-x}, & x \geq \mu \end{cases} \quad (1)$$

模型通过使用 Slide Loss 损失函数,为困难样本赋予了更高的权重,使模型在训练过程中更加注重困难样本的学习,从困难样本中提取到更有价值的特征信息,从而提高模型的整体性能。

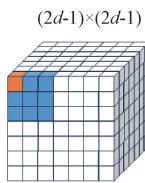
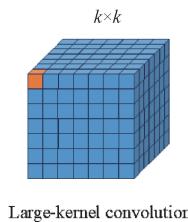
2.3 改进注意力机制

C2PSA 是在 YOLOv11 网络中 Backbone 末尾部分的新增模块,该模块由卷积层和注意力模块组成,具体结构如图 3 所示。通过跨阶段部分(cross stage partial

network, CSP) 架构与金字塔切片注意力 (positioning system architecture, PSA) 机制的结合实现高效特征提取。模块输入特征图后分为两路: 直接复制分支保留原始浅层信息以降低信息损耗, PSA 处理分支则通过堆叠多个 PSABlock 进行多尺度特征增强。每个 PSABlock 内部采用注意力分支与残差连接相加, 有效提升梯度流动并强化关键区域响应。最终, 两分支特征通过拼接融合, 兼顾浅层细节与深层语义信息。

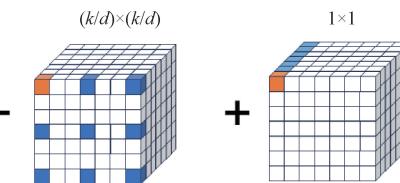
尽管 C2PSA 模块通过使用注意力机制提高了模型的性能, 但由于传统注意力无法充分利用不同尺度的特征信息, 进而影响了模型的检测效果。因此在 C2PSA 模块中引入 LSKA^[13] 注意力机制, 优化模型的特征提取和表达能力。

LSKA 大卷积核分解原理如图 4 所示, 卷积分离原理如图 5 所示。首先将卷积核分解为深度卷积、深度膨胀卷积和通道卷积, 再将深度卷积与深度膨胀卷积分别分解为



Large-kernel convolution

DW-Conv



DW-D-Conv

Conv

图 4 大核卷积分解原理图

Fig. 4 Schematic diagram of the integral solution of the large nuclear volume

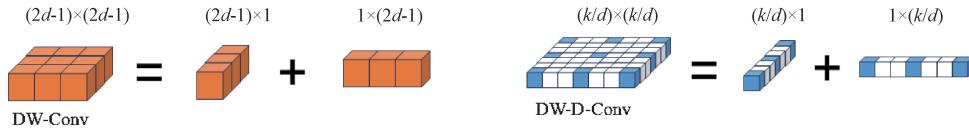


图 5 卷积分离原理图

Fig. 5 Schematic diagram of volume separation

LSKA 与大核注意力 (large kernel attention, LKA)、LKA-trivial、LSKA-trivial 结构对比如图 6 所示。与传统的 LKA-trivial、LSKA-trivial、LKA 等结构不同, LSKA 通过分离卷积核将 2D 卷积核分解为水平和垂直的 1D 卷积核, 减少了模型的计算复杂度和内存占用。通过级联的 1D 卷积核, LSKA 能够同时捕捉局部和全局的特征信息。改进后的 C2PSA 模块如图 7 所示, 在 PSABlock 中, 注意力分支的输出与 LSKA 处理后的特征通过元素融合。再经过多级特征经串联处理后, 通过 Concat 拼接融合层级信息, 最终由 Conv 调整通道维度并输出。该设计通过 LSKA 的全局-局部协同感知与多层次特征堆叠, 提高了模型的特征提取和表达能力, 显著提升模型对多尺度目标的检测鲁棒性。

2.4 改进激活函数

YOLOv11 中的卷积模块采用 SiLU 激活函数, 但 SiLU 激活函数在反向传播阶段可能会遇到梯度限制的问

题。当输入值偏大或偏小时, 梯度的变化趋于平缓, 这种情况下有可能出现梯度消失或梯度爆炸的情况。另外, 虽然 SiLU 激活函数凭借其非线性特性能够在一定程度上帮助神经网络学习复杂的非线性关系, 但在应对更为艰巨的任务时, 其非线性表达能力显得相对有限, 进而在一定程度上限制了模型的性能。SiLU 激活函数的表达式如式(2)所示。

$$f(x) = x \cdot \frac{1}{1 + e^{-x}} \quad (2)$$

因此, 改进模型采用 Mish^[14] 激活函数来替换 SiLU 激活函数。Mish 是一种具备无穷连续性和光滑性的非单调激活函数。由于 Mish 函数的梯度设计相对平滑且能够妥善保留较小的负值, 因此在反向传播过程中, 即便输入值较小, 其梯度也不会急剧下降至零, 从而有效降低了梯度消失的风险。与此同时, Mish 函数的非单调性和光滑性共同作用于网络, 有助于稳定梯度流动, 确保网络训练过程

水平卷积核与垂直卷积。

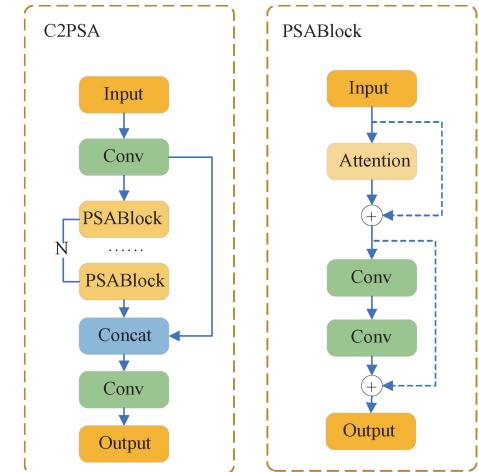
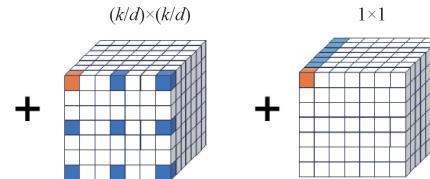
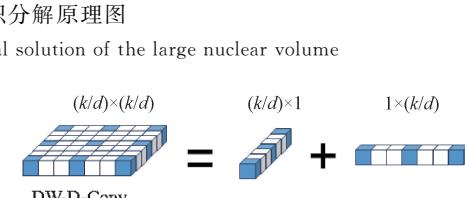


图 3 C2PSA 模块结构

Fig. 3 C2PSA module structure



PSABlock



1x1

PSABlock

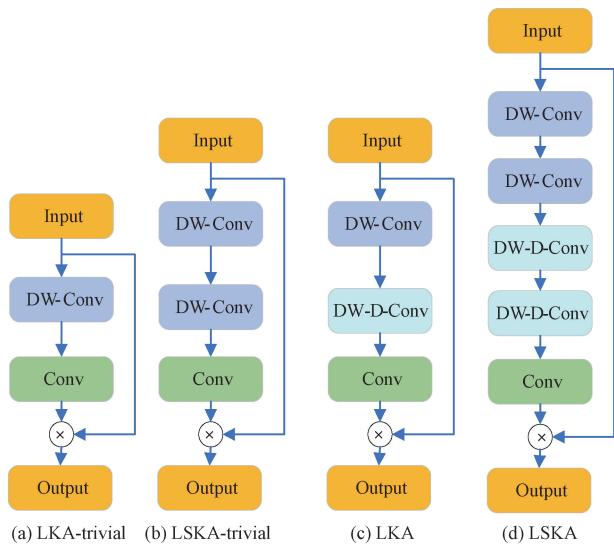


图 6 大核注意力模块结构对比

Fig. 6 Comparison of the structure of the large core attention module

的平稳性。

当输入值较大时, Mish 函数的输出增长趋势展现出一定的平缓性, 有助于规避梯度值过大引发的梯度爆炸问题。此外, Mish 激活函数具备更为复杂的形状和更为强大的非线性能力, 能够更为精准地捕捉复杂的非线性特征, 进而有效地提升模型的表达能力。Mish 激活函数的表达式如式(3)所示。

$$f(x) = x \cdot \tanh(\ln(1 + e^x)) \quad (3)$$

2.5 添加 StripPooling 池化方法

在应对长距离依赖关系及复杂背景时, 传统的 YOLO 模型仍存在一定的局限性。为克服这一难题, 改进模型引入了 Strip Pooling^[15]模块。该模块采用独特的长条形池化窗口设计, 能够高效地捕捉全局上下文信息, 提升模型在太阳能电池板缺陷检测场景下的性能表现。

Strip Pooling 结构如图 8 所示。模块由两个并行分支组成, 分别负责执行水平和垂直方向的条带池化操作。利用 1D 卷积层对初步提取的特征信息进一步调整和优化, 再将水平和垂直方向上的特征信息进行融合, 通过 1×1 卷积层及 sigmoid 函数进行处理, 最终生成权重图。

Strip Pooling 模块通过运用长条形池化窗口的设计, 能够高效地捕捉并分析分布离散区域间的关联性, 进而增强模型的全局感知能力。同时, 窄条形池化窗口的采用有助于模型聚焦于局部上下文信息, 有效减少不相关区域的干扰。改进算法在 Neck 部分的特定层后添加 Strip Pooling 模块, 以优化特征信息的筛选。

2.6 改进后 YOLOv11 模型

为提升太阳能电池板缺陷检测的精度与效率, 对 YOLOv11 算法进行了多方面优化, 改进后 YOLOv11 网络模型结构如图 9 所示。首先, 在特征提取环节引入 SimSPPF 模块, 优化了模型特征提取过程。其次, 采用 Slide Loss 损失函数, 增强了模型对困难样本的学习能力。此外, 在 C2PSA 结构中整合 LSKA 注意力机制, 结合分离卷积核的设计, 进一步强化模型特征提取能力, 并通过引入 Mish 激活函数提升网络的非线性表达能力。最后, 采

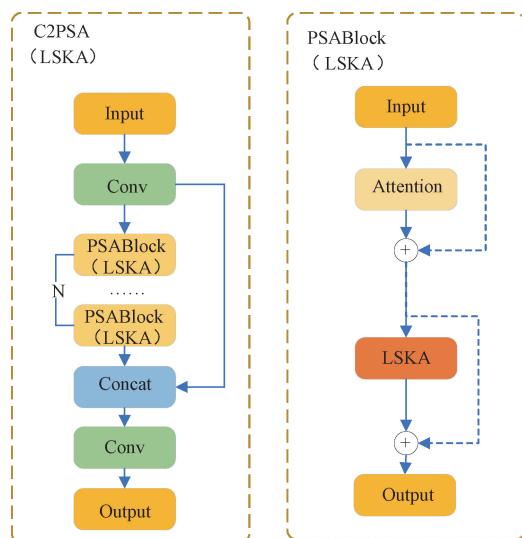


图 7 改进后 C2PSA 模块结构

Fig. 7 Improved C2PSA module structure

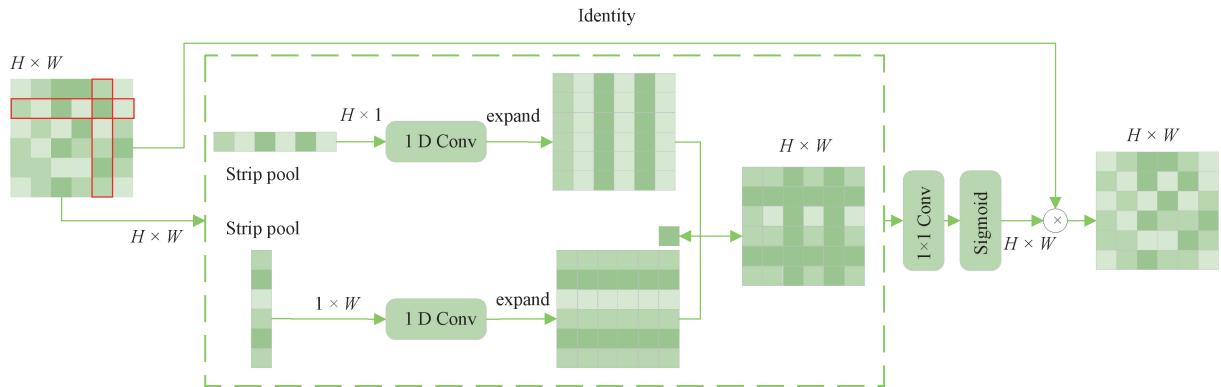


图 8 Strip Pooling 模块结构

Fig. 8 Structure of the Strip Pooling module

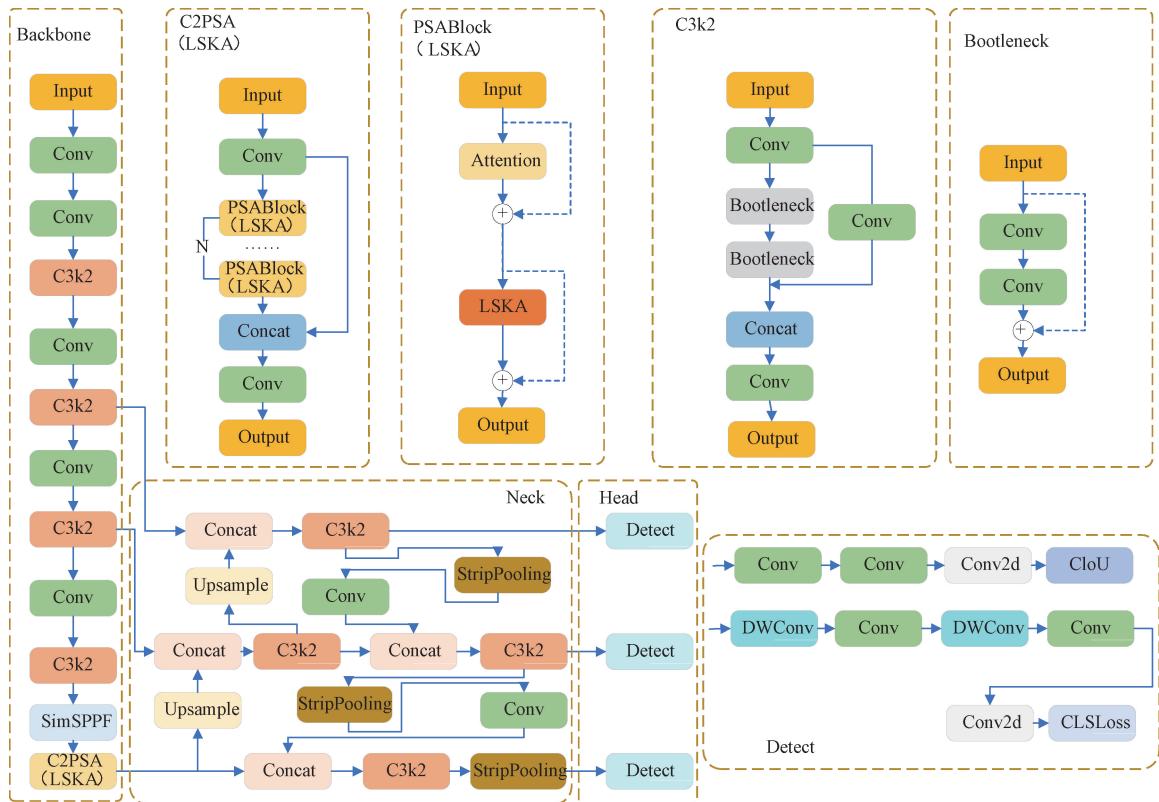


图 9 改进后的 YOLOv11 网络结构

Fig. 9 Improved YOLOv11 network

用 Strip Pooling 策略, 提高了模型对目标形态和分布变化的适应能力。

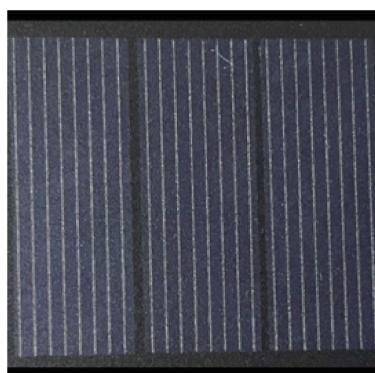
3 实验及结果分析

3.1 实验环境与数据集

本文实验选择在 Kaggle 云端平台上进行, CPU 型号为 Intel(R) Xeon(R) CPU@2.00 GHz, GPU 型号为 Tesla P100-PCIE-16 GB, python 版本为 3.10.14, pytorch 版本为

2.4.0。

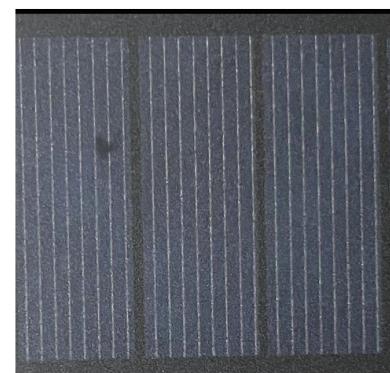
本文选用的数据集来源于飞桨平台。该数据集包括 2400 张已标注的太阳能电池板缺陷图片, 共包含划痕、断栅与脏污 3 类缺陷, 缺陷类别如图 10(a)、(b)、(c) 所示。将该数据集按照 8:1:1 的比例拆分成 1920 张训练集图片、240 张验证集图片、240 张测试集图片。数据集标注情况如图 11 所示, 各缺陷类别样本数量均衡, 能较好的满足实验要求。



(a) 划痕
(a) Crack



(b) 断栅
(b) Grid



(c) 脏污
(c) Spot

图 10 数据集缺陷类别

Fig. 10 Dataset defect category

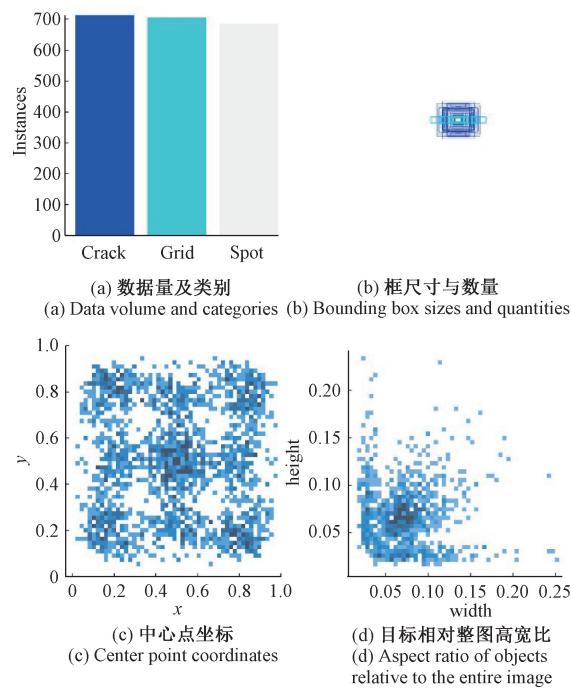


图 11 数据集标注情况

Fig. 11 Dataset labeling

3.2 算法评价指标

本文采用平均精度(average precision, AP)、召回率

(recall, R)、平均精度均值(mean AP, mAP)以及每秒检测图片的帧数(frames per second, FPS)作为评估指标来衡量相关模型的优劣情况。其中,平均精度 AP 是不同召回率下精确度的平均值。召回率 R 表示所有正样本中被正确预测为正样本的比例。平均精度均值 mAP 是指所有类别的 AP 值的平均值。评估指标公式为:

$$AP = \int_0^1 P \, dR \quad (4)$$

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \quad (5)$$

$$R = \frac{TP}{TP + FN} \quad (6)$$

$$P = \frac{TP}{TP + FP} \quad (7)$$

3.3 实验验证

1) 消融实验

为验证改进模块对模型检测效果的影响,将引入了不同模块的模型在同一数据集、同一云端平台上进行实验验证,实验结果如表 1 所示。

使用 \checkmark 表示引入该模块, \times 表示未引入该模块。由表 1 可知,引入 Mish 激活函数后,P 值提升了 0.3%,mAP 值提升 1.6%,FPS 值提高了 19.264;加入 LSKA 注意力机制后,P 值提升了 3.6%,mAP 值提升了 1.6%;同时引入

表 1 消融实验

Table 1 Ablation experiments

LSKA	SimSPPF	Mish	SlideLoss	StripPooling	P	R	mAP0.5	FPS
\times	\times	\times	\times	\times	0.835	0.873	0.875	136.986
\times	\times	\checkmark	\times	\times	0.838	0.853	0.891	156.250
\checkmark	\times	\times	\times	\times	0.871	0.845	0.891	204.082
\checkmark	\times	\checkmark	\times	\times	0.848	0.825	0.878	161.290
\checkmark	\times	\times	\checkmark	\checkmark	0.869	0.865	0.899	128.205
\times	\checkmark	\checkmark	\times	\checkmark	0.866	0.856	0.878	135.135
\checkmark	\checkmark	\times	\checkmark	\checkmark	0.848	0.842	0.880	108.696
\checkmark	\checkmark	\checkmark	\times	\checkmark	0.853	0.855	0.898	111.111
\checkmark	\checkmark	\checkmark	\checkmark	\checkmark	0.868	0.876	0.901	149.254

LSKA 注意力机制和 Mish 激活函数后,mAP 值提升了 0.3%,FPS 值相较于原模型提高了 24.304;添加 Slide Loss 损失函数、Strip Pooling 池化操作及 LSKA 注意力机制后,相较于只采用 LSKA,召回率 ReCall 提高了 2%,mAP 提高了 0.8%。同时采用多种改进后,相较于 YOLOv11 网络模型,P 值提高了 3.3%,召回率 R 值提高了 0.3%,mAP 值提高了 2.6%。FPS 值提高了 12.268。

由实验结果可知,在进行太阳能电池板缺陷检测时,本文改进算法在检测精度和检测效率方面均优于改进前

算法。为了能更加直观感受改进的有效性,将改进后模型与原始 YOLOv11 模型检测效果进行可视化对比,改进前后两个模型的 P-R 曲线对比如图 12(a)、(b)所示。由改进前后 P-R 曲线图可以看出,改进后算法在对各个缺陷类别检测时,检测性能均优于原始算法。

2) 对比实验

为进一步分析改进模型的性能,本文选取了 YOLOv11、YOLOv10^[16]、YOLOv9t^[17]、rt-detr-l^[18]、YOLOv8n^[19]、YOLOv5 以及最新的 YOLOv12^[20]进行对比实验。上述

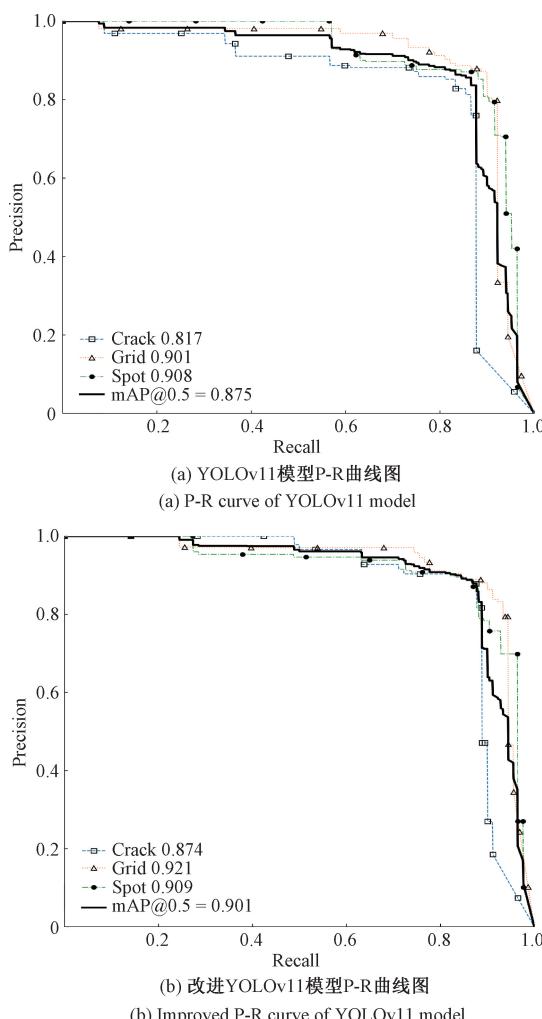


图 12 模型改进前后 P-R 曲线对比

Fig. 12 Comparison of P-R curves before and after model improvement

模型均为目标检测领域的优秀算法,具有高精度、高速度

以及良好的适应性,广泛应用于各类检测任务中。其中, YOLOv11、YOLOv10n、YOLOv9t 和 YOLOv12 代表了 YOLO 系列的最新进展,在整体性能上取得了显著提升; rt-detr-1 作为 Transformer-based 模型的代表,提供了与传统 CNN 架构的性能对比; YOLOv8n 和 YOLOv5 则是太阳能电池板缺陷检测领域广泛应用的基准模型。

通过与上述优秀模型对比,可以更全面地评估在进行太阳能电池板缺陷检测时,本文改进算法在检测精度、检测速度上的优越性。为保证实验公平性,所有模型均在相同数据集、相同实验环境下进行检测,实验结果如表 2 所示。由对比实验结果可知,相较于其他算法,改进算法在 mAP0.5 方面表现最优。同时,改进后的模型在召回率和检测速度等方面也表现良好。

表 2 对比实验

Table 2 Comparative experiments

模型	P	R	mAP0.5	FPS
YOLOv12	0.863	0.695	0.778	149.254
YOLOv11	0.835	0.873	0.875	136.986
YOLOv10n	0.871	0.764	0.858	250.000
YOLOv9t	0.841	0.866	0.899	149.254
rt-detr-1	0.854	0.883	0.867	49.505
YOLOv8n	0.888	0.847	0.889	217.391
YOLOv5	0.891	0.847	0.893	200.000
Ours	0.868	0.876	0.901	149.254

模型改进前后检测结果如图 13、14 所示,由检测结果图可知,改进后算法在进行太阳能电池板缺陷检测时,检测效果得到了显著的提高。以上结果显示,本文改进算法在太阳能电池板缺陷检测领域具有重要价值,可满足工业场景下太阳能电池板缺陷高精度、高效率的检测要求。

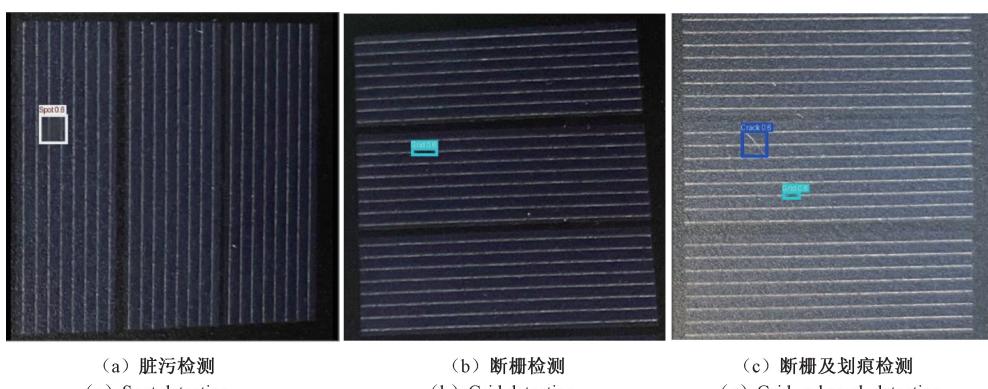


图 13 YOLOv11 模型检测结果图

Fig. 13 Detection results of the YOLOv11 model

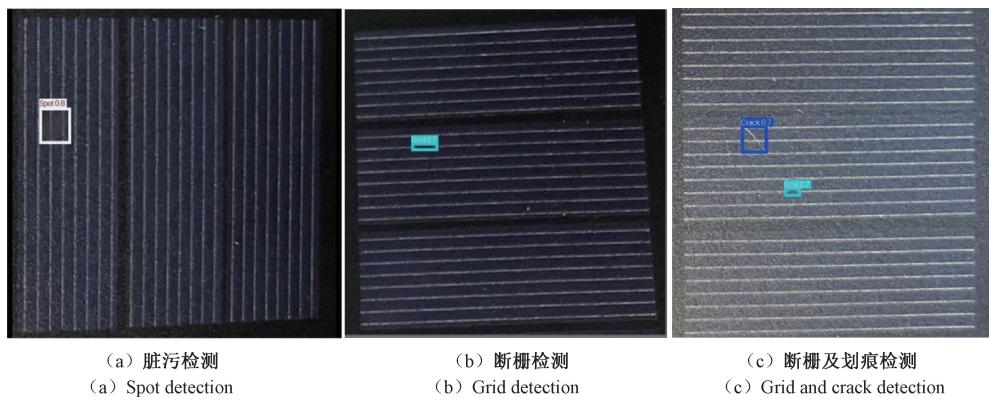


图 14 改进 YOLOv11 模型检测结果图

Fig. 14 The detection result graph of the YOLOv11 model was improved

4 结 论

本文针对传统的太阳能电池板缺陷检测算法精度低、速度慢的问题,采取了一系列的改进措施,提出了一种新型的改进 YOLOv11 缺陷检测算法。经过实验证,改进算法在检测精度方面,超过 YOLOv10 n、YOLOv9t、rt-detr-l 等网络模型。与原始 YOLOv11 算法进行对比,改进后的算法在检测精度和检测速度方面都表现出更好的性能,可满足工业生产中太阳能电池板缺陷检测的高效率和高精度需求,为太阳能电池板缺陷检测提供了一种新型的解决方法。

在未来工作中,将进一步深入太阳能电池板缺陷检测研究。通过数据蒸馏等技术实现模型的轻量化,使模型更易部署。同时,将借鉴更加先进的算法思想,进一步提高太阳能电池板缺陷检测算法的检测精度和检测速度。

参考文献

- [1] 陈光耀,陈田,高学海,等.跨层融合的轻量化太阳能电池片缺陷分割方法[J].电子测量技术,2024,47(24):118-127.
CHEN G Y, CHEN T, GAO X H, et al. Defect segmentation method for lightweight solar cells based on cross-layer fusion [J]. Electronic Measurement Technology, 2024, 47(24):118-127.
- [2] 崔康,陈平.基于孪生网络的自监督太阳能电池板裂纹检测方法[J].国外电子测量技术,2024,43(3):177-182.
CUI K, CHEN P. Crack detection method of self-supervised solar panel based on siamese network[J]. Foreign Electronic Measurement Technology, 2024, 43(3): 177-182.
- [3] TANG W Q, YANG Q, DAI ZH, et al. Module defect detection and diagnosis for intelligent maintenance of solar photovoltaic plants: techniques, systems and perspectives[J]. Energy, 2024: 131222.
- [4] 高航,祁云嵩.基于 YOLOv8n 改进的太阳能电池板缺陷检测[J].电子测量技术,2024,47(24):118-127.
GAO H, QI Y S. Improved defect detection of solar panels based on YOLOv8n [J/OL]. Infrared Technology, 1-7 [2025-04-03]. <http://kns.cnki.net/kcms/detail/53.1053.TN,20240923.0931.002.html>.
- [5] MENG Z Y, XU SH ZH, WANG L CH, et al. Defect object detection algorithm for electroluminescence image defects of photovoltaic modules based on deep learning[J]. Energy Science & Engineering, 2022, 10(3): 800-813.
- [6] LI L L, WANG ZH F, ZHANG T T. Gbh-YOLOv5: Ghost convolution with bottlenecksp and tiny target prediction head incorporating YOLOv5 for pv panel defect detection[J]. Electronics, 2023, 12(3): 561.
- [7] 张猛,尹丽菊,周辉,等.基于 SimAM-Ada YOLOv5 的太阳能电池表面缺陷检测[J].电子测量技术,2023,46(22):17-25.
ZHANG M, YIN L J, ZHOU H, et al. Surface defect detection of solar cells based on SimAM-Ada YOLOv5[J]. Electronic Measurement Technology, 2023, 46(22):17-25.
- [8] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements[J]. ArXiv preprint arXiv:2410.17725, 2024.
- [9] 李彬,李生林.改进 YOLOv11n 的无人机小目标检测算法[J/OL].计算机工程与应用,1-11 [2025-04-03]. <http://kns.cnki.net/kcms/detail/11.2127.TP,20241223.1319.020.html>.
- LI B, LI SH L. Improving YOLOv11n's UAV small target detection algorithm [J/OL]. Computer Engineering and Application, 1-11 [2025-04-03]. <http://kns.cnki.net/kcms/detail/11.2127.TP,20241223.1319.020.html>.

- [10] LI CH Y, LI L L, JIANG H L, et al. YOLOv6: A single-stage object detection framework for industrial applications[J]. ArXiv preprint arXiv:2209.02976,2022.
- [11] ELFWING S, UCHIBE E, DOYA K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning[J]. Neural Networks,2018, 107: 3-11.
- [12] YU Z P, HUANG H B, CHEN W J, et al. YOLO-FaceV2: A scale and occlusion aware face detector[J]. Pattern Recognition,2024,155:110714.
- [13] LAU K W, PO L M, REHMAN Y A U. Large separable kernel attention: Rethinking the large kernel attention design in CNN[J]. Expert Systems with Applications,2024, 236: 121352.
- [14] MISRA D. Mish: A self regularized non-monotonic activation function [J]. ArXiv preprint arXiv: 1908.08681,2019.
- [15] HOU Q B, ZHANG L, CHENG M M, et al. Strip pooling: Rethinking spatial pooling for scene parsing[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition,2020:4003-4012.
- [16] WANG AO, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv:2405.14458,2024.
- [17] WANG C Y, YEH I H, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]. European Conference on Computer Vision, Cham: Springer Nature Switzerland, 2024: 1-21.
- [18] ZHAO Y AN, LYU W Y, XU SH L, et al. Detrs beat yolos on real-time object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition,2024: 16965-16974.
- [19] VARGHESE R, SAMBATH M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness[C]. 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems(ADICS). IEEE, 2024: 1-6.
- [20] TIAN Y J, YE Q X, DOERMANN D. YOLOv12: Attention-centric real-time object detectors[J]. ArXiv preprint arXiv:2502.12524,2025.

作者简介

包广斌,副教授,研究生导师,博士,主要研究方向为计算机网络体系结构、人工智能、计算机视觉和图像处理。
E-mail: bao_gb@qq.com

范超林(通信作者),硕士研究生,主要研究方向为人工智能、计算机视觉。
E-mail: 2530985059@qq.com