

doi:10.6041/j.issn.1000-1298.2024.07.029

# 基于 FPGA 加速的 Mask R – CNN 稻瘟病高通量自适应识别模型研究

杨 宁<sup>1</sup> 程 巍<sup>1</sup> 张钊源<sup>1</sup> 方 嗣<sup>1</sup> 毛罕平<sup>2</sup>

(1. 江苏大学电气信息工程学院, 镇江 212013; 2. 江苏大学农业工程学院, 镇江 212013)

**摘要:** 针对基于图像的稻瘟病现场检测技术依赖先验知识且受制于算力与田间网络状况, 无法实现自适应实时检测的问题, 提出一种可利用现场可编程门阵列(Field programmable gate array, FPGA)加速的 Mask R – CNN(Mask region-based convolutional neural network)稻瘟病高通量自适应快速识别模型。首先将骨干网络改进为 MobileNetV2, 利用其倒残差模块降低计算量, 提高模型并行处理能力; 随后增加用于稻瘟病多尺度特征融合的特征金字塔网络模块, 使模型具备多尺度自适应处理能力; 最后由全卷积网络(Fully convolutional network, FCN)分支输出稻瘟病病斑的实例分割, 同时使用交叉熵损失函数完成稻瘟病的定位与分类。稻瘟病实测数据集对模型的验证结果表明: 当输入为全高清图像时, 模型平均推理时间减少至 85 ms, 相较 GPU 服务器、同级别 GPU 边缘计算平台, 速度分别提高 86.2%、63.0%。在交并比为 0.6 时, 准确率可达 98.0%, 病斑捕获能力平均提升 21.2%。提出的 Mask R – CNN 自适应快速识别模型能够在田间恶劣网络状况下实现稻瘟病的快速现场检测, 具有更好的抗噪能力和鲁棒性能, 为水稻病害实时检测、察打一体提供了高效实时的片上系统方案。

**关键词:** 稻瘟病检测; 目标检测; Mask R – CNN; 现场可编程门阵列中图分类号: S435.111.41; TP391.4 文献标识码: A 文章编号: 1000-1298(2024)07-0298-07 OSID: 

## Research on High-throughput Adaptive Recognition Mask R – CNN Model for Rice Blast Disease Based on FPGA Acceleration

YANG Ning<sup>1</sup> CHENG Wei<sup>1</sup> ZHANG Zhaoyuan<sup>1</sup> FANG Xiao<sup>1</sup> MAO Hanping<sup>2</sup>

(1. School of Electrical Information and Engineering, Jiangsu University, Zhenjiang 212013, China)

2. School of Agricultural Engineering, Jiangsu University, Zhenjiang 212013, China)

**Abstract:** Image-based on-site detection technology for rice blast relies on prior knowledge which is affected by computational power and field network conditions, rendering adaptive real-time detection impossible. To tackle these challenges, a Mask R – CNN (Mask region-based convolutional neural network) model for rapid, high-throughput, and adaptive identification of rice blast was proposed. This model can be accelerated by using field programmable gate array (FPGA). Firstly, the backbone network was replaced with MobileNetV2, leveraging its inverted residual module to decrease computations and enhance the model's parallel processing capabilities. Following that, a feature pyramid network module was incorporated to facilitate multi-scale feature fusion for rice blast, enabling the model to possess multi-scale adaptive processing abilities. Finally, the fully convolutional network (FCN) branch outputted the instance segmentation of rice blast lesions, utilizing the Softmax function to accurately localize and classify rice blast diseases. The validation results of the model using test datasets for rice blast disease demonstrated significant capabilities: when the input was a full HD image, the average inference time of the model was reduced to 85 ms, which was 86.2% and 63.0% faster than the GPU server and the same level GPU edge computing platform, respectively. When the intersection over union ratio was 0.6, the accuracy can reach 98.0%, and the disease spot capture ability was improved by 21.2% on average. The Mask R – CNN adaptive fast identification model proposed can realize the rapid field detection of rice blast disease under severe network conditions, and had better anti-noise ability and robust performance, which provided an efficient real-time system-on-chip scheme for real-time detection, inspection and mitigation of rice disease.

**Key words:** rice blast detection; object detection; Mask R – CNN; FPGA

收稿日期: 2023-11-15 修回日期: 2024-01-23

基金项目: 国家重点研发计划青年科学家项目(2022YFD2000200)和国家自然科学基金(面上)项目(32171895)

作者简介: 杨宁(1984—), 男, 教授, 博士, 主要从事智慧农业作物病害预警研究, E-mail: yangning7410@163.com

通信作者: 毛罕平(1961—), 男, 教授, 博士, 主要从事智能化农业装备技术研究, E-mail: maohp@ujs.edu.cn

## 0 引言

高速移动网络在偏远大田环境的覆盖率极低,因此目前稻瘟病的检测方法仍以实验室显微镜观察法为主,从样本采集到结果分析均需要专业人员操作且效率较低<sup>[1]</sup>,严重制约农田数据的实时采集和云端分析。遥感技术虽然提高了稻瘟病检测精准度和自动化程度,但受制于搭载设备的算力资源与当地网络状况,稻瘟病检出过程效率较低且检测结果存在严重时延,无法兼备远程监控和实时检测的功能。

相较于使用显微镜人工观察病菌孢子,齐龙等<sup>[2]</sup>提出一种基于显微图像处理技术的稻瘟病菌孢子自动检测和计数方法,准确率达 98.5%,提升了实验室中稻瘟病检测效率。YANG 等<sup>[3]</sup>通过采集稻瘟病孢子,提取孢子衍射图像特征进行病害识别,该方法将衍射光学原理与图像处理结合,创新实验室内检测方法。刘潭等<sup>[4]</sup>提出了使用 LMPSO-SVM 算法对稻瘟病高光谱图像进行病害分级检测。以上方法都在一定程度上提高了人工检测的效率,但受制于大田环境,无法满足现代农业水稻大田种植场景下现场快检。

在边缘计算现场检测技术应用上,ZHAO 等<sup>[5]</sup>基于英伟达 Jetson 边缘计算平台,为不同尺度椭球缺陷种子的全表面检测提供了一种方法。刘佳辉等<sup>[6]</sup>利用国产微控制芯片 K210 配合国产实时操作系统搭建了农业病虫害检测系统。然而,现场可编程门阵列(Field programmable gate array, FPGA)相较于 GPU 或者 RISC-V 架构的芯片,在功耗、处理能力与灵活性上更具优势。这些优势使其成为一种更好的神经网络模型加速器<sup>[7]</sup>。其独立专用的 IP 核可以对矩阵运算、卷积计算、非线性激活等神经网络计算操作进行硬件加速<sup>[8]</sup>。LUO 等<sup>[9]</sup>提出利用 FPGA 加速的 LiteCNN 模型对植物病害进行实时识别,证明了深度学习结合 FPGA 应用于稻瘟病现场快速检测的可行性。

在深度学习算法上,资彩飞等<sup>[10]</sup>使用 TensorFlow-Keras 框架对健康水稻与稻瘟病图像集建立神经网络模型,稻瘟病识别率达 78%。路阳等<sup>[11]</sup>研究水稻叶部病害图像,先使用主成分分析法降维,再基于 Caffe 深度学习框架训练病害图像数据,对北方寒地水稻稻瘟病平均识别率达 96.9%。朱红春等<sup>[12]</sup>应用一种区域卷积神经网络(Region-convolutional neural network, R-CNN)算法,将病斑图像位置预测与病害分类相结合,在检测病害时进一步定位稻瘟病病斑位置。刘莫尘等<sup>[13]</sup>使用了一

种 MSRCR-YOLOv4-tiny 的目标检测模型检测识别玉米的田间杂草。从模型轻量化角度出发,李书琴等<sup>[14]</sup>提出了一种轻量级残差网络来识别植物病害,王泽钧等<sup>[15]</sup>使用注意力机制和多尺度轻量型网络用于农作物病害检测,对检测模型的结构向移动应用适用性作出较大优化。

但以上算法模型与研究也存在不足:常规模型需要使用较大算力的 GPU 服务器来进行推理,不稳定的网络开销使其不适用于现场大面积检测场景;GPU 或 RISC-V 方案在加速能力与开发灵活性上达不到同级别成本的 FPGA 的性能;通用轻量级农作物病害类的模型结构研究对象是基于叶片病斑形态相差较小的作物,直接套用与病斑尺度相差较大的稻瘟病病斑检测时,不能很好地提取并融合稻瘟病特征,导致精确度不高。

因此,本文提出一种基于针对稻瘟病病害特点优化的 Mask R-CNN 方法<sup>[16]</sup>,经过 FPGA 平台的模型量化与加速卷积计算,对水稻叶片稻瘟病病斑进行快速检测和实例分割,以满足水稻大田场景下专用边缘终端或无人机进行稻瘟病快速识别需求。

## 1 实验装置与数据获取

### 1.1 图像数据集

稻瘟病主要的叶瘟症状图像数据集 dataset3 采用感光芯片为 OV2710、焦距为 2.7 mm 的免驱 USB 摄像头实地拍摄。dataset1 与 dataset2 为收集自网络的数据集。预训练权重来自 MS COCO<sup>[17]</sup> 数据集,使用标记工具 Labelme<sup>[18]</sup> 标记病害区域,共标记区域 8 590 处。图 1 为 3 个数据集中的图像样例以及现场拍摄用摄像头,表 1 为全部数据集标记信息。图 2 为以现场拍摄数据为例的处理过程。

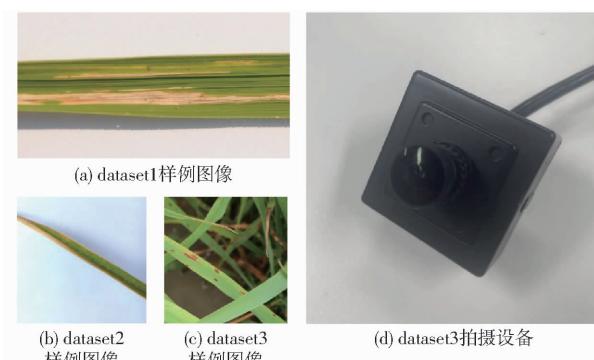


图 1 样例图像与拍摄设备

Fig. 1 Sample images and capture device

### 1.2 训练环境与 FPGA 加速平台

模型的训练服务器搭载 2 块 Nvidia Tesla T4 16GB 显存的显卡,训练时采用多 GPU 并行的任务分配策略。FPGA 加速平台选用 Xilinx 公司的

表 1 稻瘟病叶片图像数据集

Tab. 1 Leaf image datasets of rice blast

数据集	来源	样本总数	标记区域
dataset1 Kaggle 水稻病害叶片数据集		350	1 563
dataset2 Kaggle 孟加拉国作物病害数据集		977	2 138
dataset3 现场所拍摄水稻病害叶片数据集		400	4 889

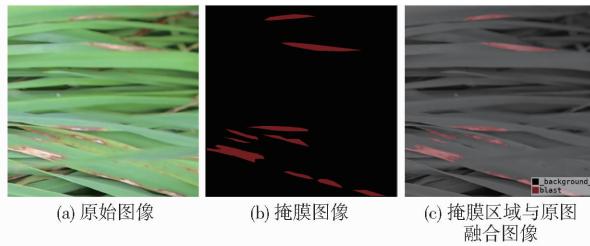


图 2 图像处理过程

Fig. 2 Image processing process

KV260 SOM 开发板。服务器与 FPGA 板载操作系统版本均为 Ubuntu 20.04, 实验程序主要在赛灵思 Vitis 软件平台上使用 Python 与 C++ 语言编写。FPGA 的核心器件为赛灵思 Zynq MPSoC, 包含 256 KB 系统逻辑单元以及 1.2 KB 的 DSP 片。

## 2 改进的 Mask R - CNN 片上算法

### 2.1 模型前端压缩

基准 Mask R - CNN 的主干网络部分使用的是 ResNet<sup>[19]</sup> 网络, 本文将 ResNet 替换为 MobileNetV2<sup>[20]</sup>, 由深度可分离卷积、线性瓶颈 (bottleneck) 与倒置残差模块<sup>[21]</sup>组成, 深度可分离卷积计算成本  $C$  计算公式为

$$C = h_i w_i d_i (k^2 + d_i) \quad (1)$$

式中,  $h_i$ 、 $w_i$ 、 $d_i$  为输入图像高、宽、通道数,  $k$  为卷积核大小。将其作为输入张量, 使用卷积核  $R^{k^2 + d_i d_j}$  来产生输出张量, 其中  $d_j$  为输出通道数, 表 2 为其网络结构<sup>[20]</sup>。

表 2 MobileNetV2 网络结构

Tab. 2 MobileNetV2 network structure

输入	网络层	扩展因子	输出通道	重复次数	步长
$224 \times 224 \times 3$	conv2d		32	1	2
$112 \times 112 \times 32$	bottleneck	1	16	1	1
$112 \times 112 \times 16$	bottleneck	6	24	2	2
$56 \times 56 \times 24$	bottleneck	6	32	3	2
$28 \times 28 \times 32$	bottleneck	6	64	4	2
$14 \times 14 \times 64$	bottleneck	6	96	3	1
$14 \times 14 \times 96$	bottleneck	6	160	3	2
$7 \times 7 \times 160$	bottleneck	6	320	1	1
$7 \times 7 \times 320$	conv2d 1 × 1		1 280	1	1

倒置残差模块加深了网络层数, 能够在保持较

高准确度的同时, 大幅减小模型参数量和计算量, 非常适合包括 FPGA 在内的嵌入式设备等资源受限的移动应用场景使用。

### 2.2 改进特征融合模块

特征金字塔网络 (Feature pyramid network, FPN)<sup>[22]</sup> 的作用是使低级特征在跨层上采样过程中被映射传播到更高层级的特征图中。但不同尺度的特征包含着不同抽象层次的信息, 它们之间存在着较大的语义差距。因此需要将语义信息较强的低分辨率特征与空间信息更多的高分辨率特征图进行融合<sup>[23]</sup>。

FPN 特征融合模块 {C2, C3, C4, C5} 为多尺度采样输入, 将最高层 M5 特征图采用自顶向下的方式传播, 并与低层特征图 {M4, M3, M2} 逐步融合。然后在 C5 层使用比例不变自适应池化操作 (Adaptive pooling, AP)<sup>[24]</sup> 处理多个尺度的特征图。最后使用自适应空间融合模块 (Automatic spacial fusion, ASF) 组合这些上下文特征。ASF 流程细节如图 3 所示, 将上采样的特征作为输入, 并为每个特征生成一个空间权重图, 利用权值将上下文特征聚合输出 M6 层, 赋予其多尺度的上下文信息。将 ASF 生成的 M6 与 M5 求和, 之后 {M2 ~ M6} 输入 RPN 网络, 同时 {M2 ~ M5} 作为感兴趣区域对齐操作的输入。

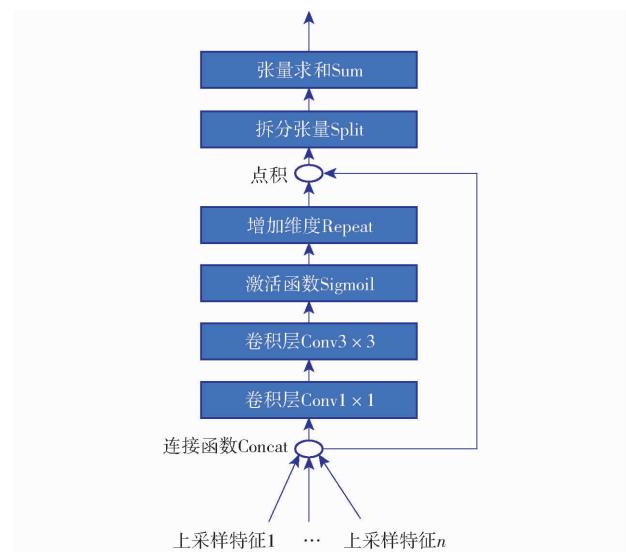


图 3 ASF 流程细节

Fig. 3 ASF process details

改进后整体网络结构如图 4 所示。特征融合模块采取了自适应池化与空间融合, 减少了最高层金字塔中对于小目标稻瘟病病斑特征图的信息损失, 最终损失函数  $L$  计算公式为

$$L = \lambda_1 \frac{1}{N_{\text{reg}}} \sum_i \sum_{j \in [x, y, w, h]} L_{\text{smooth}_{L_1}}(t_i^{(j)}, t_i^{(j)}) + \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(y_i, p_i) + \lambda_2 \frac{1}{N_{\text{mask}}} \sum_i L_{\text{mask}}(m_i, \text{roi}(i)) \quad (2)$$

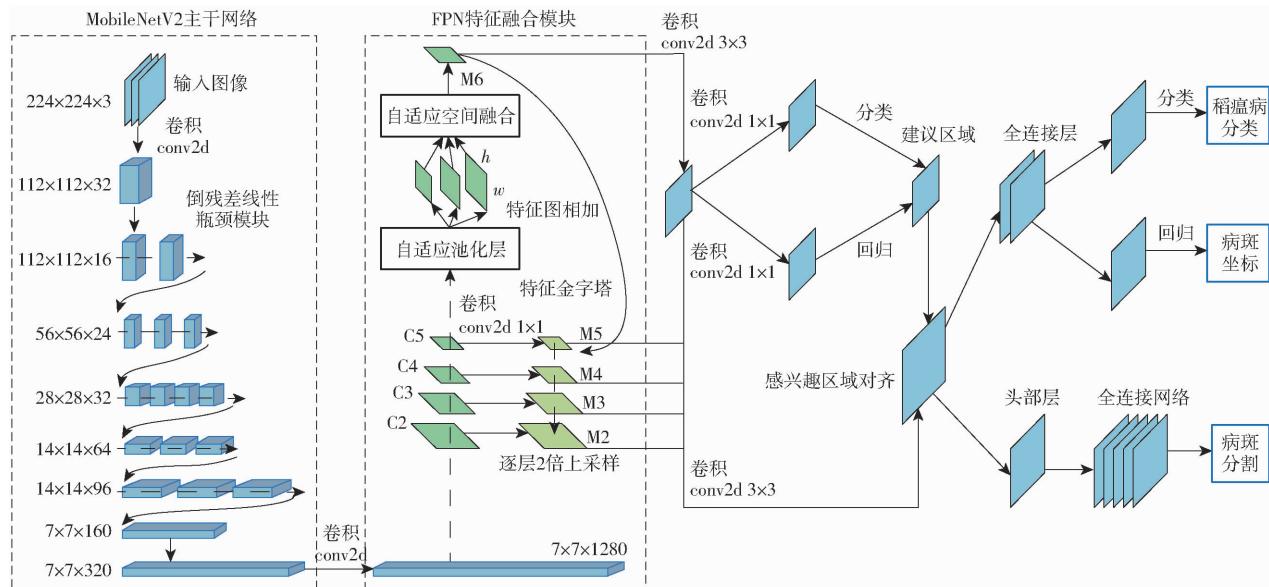


图4 改进后 Mask R-CNN 整体网络结构

Fig. 4 Overall network structure of Mask R-CNN after improvement

式中  $\text{roi}(i)$ ——第  $i$  个感兴趣区域 (Region of interest, ROI)

$y_i$ ——第  $i$  个 ROI 的真实类别

$t_i^{(x)}, t_i^{(y)}$ ——第  $i$  个 ROI 的水平和垂直位置的真实偏移量

$t_i^{(w)}, t_i^{(h)}$ ——第  $i$  个 ROI 的宽度和高度真实偏移量

$p_i$ ——第  $i$  个 ROI 的分类概率

$m_i$ ——第  $i$  个 ROI 中的目标像素和背景像素之间的差异

$L_{\text{cls}}$ ——交叉熵损失函数

$L_{\text{smooth}_{L_1}}$ ——Smooth  $L_1$  损失函数<sup>[25]</sup>

$L_{\text{mask}}$ ——二分类交叉熵损失函数, 用于衡量像素掩码预测与真实掩码之间的差异

$\lambda_1, \lambda_2$ ——平衡项, 用于平衡不同部分损失对总损失的贡献

$N_{\text{cls}}, N_{\text{reg}}, N_{\text{mask}}$ ——各自 ROI 区域的数量, 用于对损失进行归一化

### 3 模型后端压缩与 FPGA 加速计算

因为 FPGA 片上储存容量有限, 当前病害图像检测模型又需要兼顾分割、检测与分类的性能, 就需要将模型进一步后端压缩。采用参数量化方法将 32 位长浮点数据类型替换为 8 位短定点数据类型。数据转换公式为

$$n = \sum_{i=0}^{b_w-1} 2^{i-f_l} b_i \quad (3)$$

式中  $f_l$ ——量化精度小数位长度

$b_w$ ——定点数位宽

$b_i$ ——量化数据位

主干网络倒残差线性瓶颈模块内部层之间使用式(3)中的静态  $f_l$  值, 进一步使用动态精度量化卷积层与全连接层权重, 动态  $f_l$  值计算公式为

$$f_l = \arg \min_{f_l} \sum |W_f - W(b_w, f_l)| \quad (4)$$

式中  $W_f$ ——浮点权重

$W(b_w, f_l)$ ——量化后权重

因此在同一连接层内量化误差之和的最小值即为邻域内最优解。

现有 FPGA 平台多采用多处理器架构, 即处理系统 (Processing system, PS) 由 ARM 负责, 位于可编程逻辑 (Programmable logic, PL) 的深度学习处理单元 (Deep-learning processing unit, DPU) 是用于卷积神经网络运算的专用处理器知识产权核, 用于在处理引擎 (Processing engine, PE) 单元加速完成卷积计算、加法树、非线性模块、池化模块、偏置变换运算<sup>[26]</sup>, 其中卷积计算占整个模型加速计算的大部分。参数量化后, 每个 PE 单元中的卷积运算单元通过单个 16 位乘法器实现 2 个 8 位乘法后输入加法树。PL 中布置多个 PE 单元并行计算, 从而实现推理加速。模型推理时的卷积运算单元如图 5 所示。

### 4 实验

#### 4.1 模型训练 (对比数据集验证、扩展因子)

将稻瘟病图像数据集按比例 6:3:1 划分为训练集、验证集、测试集, 在服务器上使用原网络结构与改进后的网络结构分别进行 50 个周期的训练, 模型

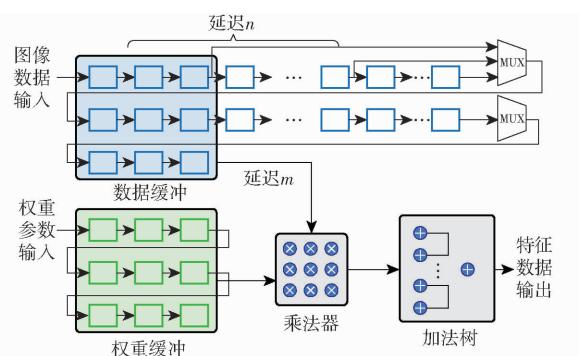


图 5 卷积运算单元

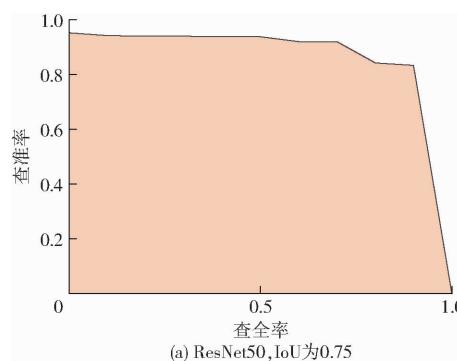
Fig. 5 Convolution operation unit

训练参数如表 3 所示。改进前后的模型训练总体损失对比如图 6 所示, 可以看出由于改进的模型网络参数大幅度减少, 相对于原模型, 在接近 30 个周期

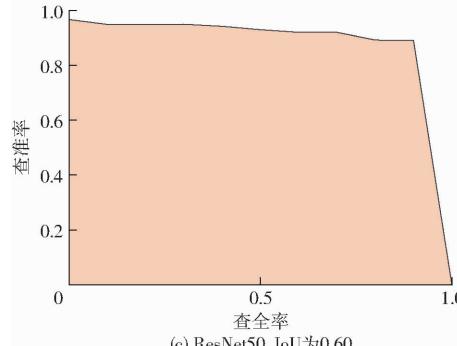
表 3 模型训练基本参数设置

Tab. 3 Model training parameter settings

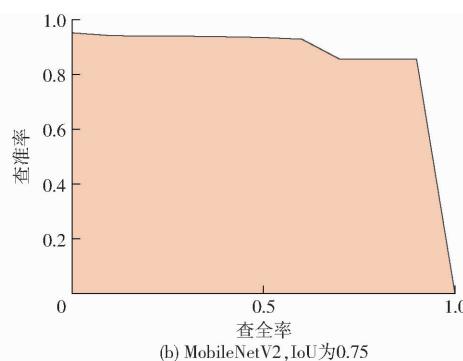
参数	数值/模块
主干网络	MobileNetV2 + FPN
类别数(含背景)	2
ROI 推荐最小置信度	0.75
区域生成网络锚点尺寸	8 × 6, 16 × 6, 32 × 6, 64 × 6, 128 × 6
每幅图像建议 ROI 数量	16
每个训练周期的数据量	50
验证步长	2
图像最大尺寸/(像素 × 像素)	1 024 × 1 024
图像最小尺寸/(像素 × 像素)	224 × 224
动量	0.92
学习率	0.000 1
掩膜池化尺寸	14



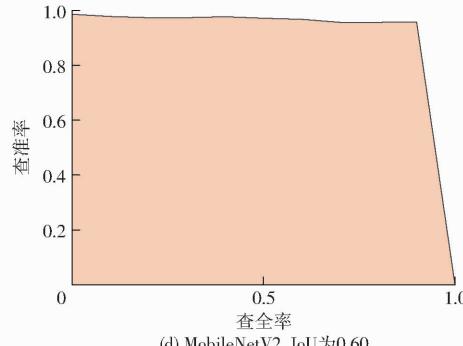
(a) ResNet50, IoU为0.75



(c) ResNet50, IoU为0.60



(b) MobileNetV2, IoU为0.75



(d) MobileNetV2, IoU为0.60

图 7 模型改进前后在不同交并比下 PR 曲线对比

Fig. 7 Comparison of PR curves under different IoUs before and after model improvement

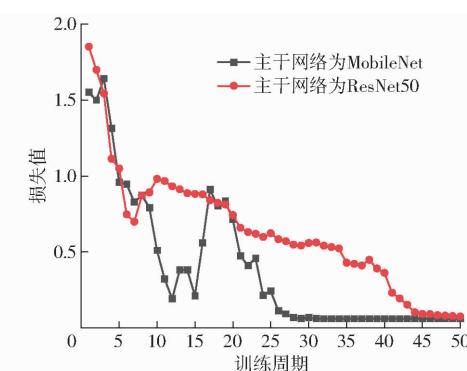


图 6 模型改进前后验证损失跟随训练轮次对比曲线

Fig. 6 Comparison curves of validation losses followed by training rounds before and after model improvement

的训练步骤后, 提前达到收敛。验证了改进后模型在保证全局损失稳定收敛的前提下, 权重参数的减少可减小计算量。

使用交并比(Intersection over union, IoU)与平均精确率(Average precision, AP)对比改进前后模型分割性能。AP 即查准率-查全率(Precision recall, PR)曲线围绕坐标轴面积, 面积越大, AP 越大。图 7 为不同 IoU 下, 测试数据在模型改进前后的 PR 曲线。表 4 为交并比在 0.75 与 0.60 时, 对应的模型改进前后平均精确率。在同样交并比下, 改进后模型均有提高。

进一步分析 MobileNetV2 中倒置残差网络模块中的拓展因子对 IoU 的影响。如图 8 所示, 当扩展因子为 6 时, 模型在不同尺度数据集下的 IoU 最高, 且相差较小, 平均精确率达 98.0%, 提升 2.7

表 4 不同交并比下模型改进前后平均精确率

Tab. 4 AP before and after model improvement under different IoUs

模型	交并比	平均精确率/%
ResNet50 + FPN	0.75	88.9
MobileNetV2 + FPN	0.75	91.3
ResNet50 + FPN	0.60	95.3
MobileNetV2 + FPN	0.60	98.0

个百分点。

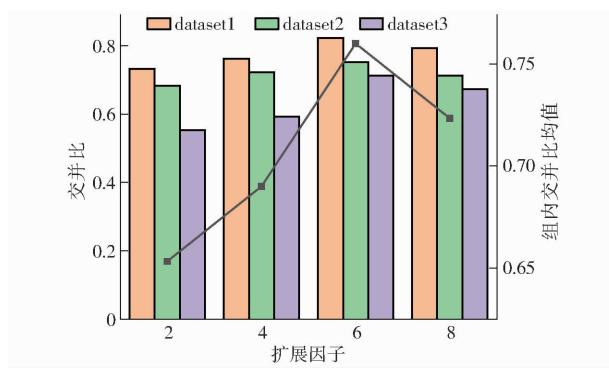


图 8 不同倒置残差网络扩展因子时各数据集中的交并比

Fig. 8 Expansion factor value of inverse residual network versus IoU performance of model in each data set

## 4.2 模型推理

将编译好的 .so 加速库文件与应用程序放在 FPGA 开发板中同一目录下, 使用 DNNDK API 对库文件进行解析, 让 DPU 参照库文件按照预定的方式运行, 最后使用 API 从 DPU 划分的内存中取出数据并显示。并分别在英伟达 Xavier NX 边缘计算终端以及 Tesla GPU 服务器推理系统中使用 TensorRT<sup>[27]</sup>

表 5 模型改进前后分别在 FPGA 与 GPU 平台的推理性能

Tab. 5 Inference performance on FPGA and GPU platforms before and after model improvement

模型	模型内存占用量/MB	总耗时/ms	图 1 掩膜区域面积/像素	图 2 掩膜区域面积/像素
FPGA (MobileNetV2 + FPN)	6.5	85		
Xavier NX (MobileNetV2 + FPN)	26	230 (63.0% ↓)	24 585 (10.4% ↑)	672 (32.0% ↑)
Tesla T4 (MobileNetV2 + FPN)	26	600 + 16 (86.2% ↓)		
FPGA (ResNet50 + FPN)	32.5	160		
Xavier NX (ResNet50 + FPN)	130	395	22 269	509
Tesla T4 (ResNet50 + FPN)	130	600 + 45		

## 5 结论

(1) 将 Mask R-CNN 的骨干网络由 ResNet50 替换为 MobileNetV2 这类轻量级网络, 并利用 FPGA 的模型量化器进一步压缩, 模型的超参数与内存占用量可压缩至 6.5 MB, 为原有模型的 1/20。

(2) Mask R-CNN 中的 FPN 网络经过自定义添加的特征层, 可以优化叶片在不同尺度下病斑特征捕获的分割准确度, 在交并比为 0.6 时的平均精确率达 98.0%, 比原模型高 2.7 个百分点。在 IoU

设置为 0.5 的模型推理模式下, 粗粒度病斑捕获像素量增加 10.4%, 细粒度病斑捕获像素量增加 32.0%, 平均增加 21.2%。

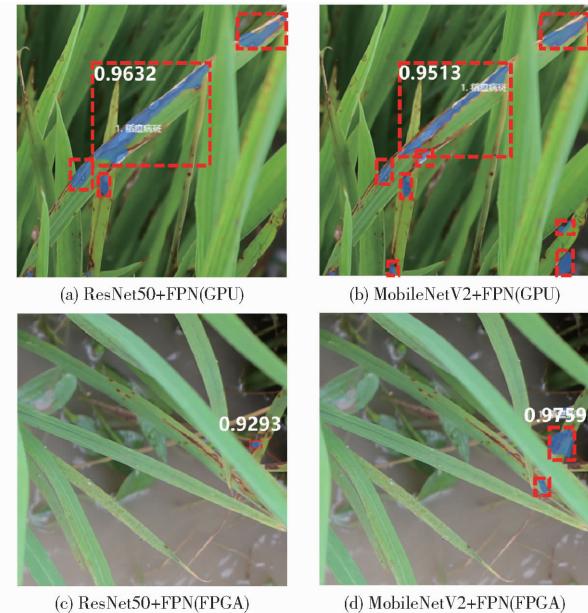


图 9 2 幅图像在不同平台的推理结果

Fig. 9 Inference results of two images on different platforms

设置为 0.5 的模型推理模式下, 粗粒度病斑捕获像素量增加 10.4%, 细粒度病斑捕获像素量增加 32.0%, 平均增加 21.2%。

(3) 利用 FPGA 中 PL 部分专门处理神经网络计算的知识产权核可以大幅度加快模型推理速度, 单次推理时间为 85 ms, 即处理能力达到 12 f/s, 比使用连接网络的 GPU 服务器提升 86.2%, 较成本相当的 GPU 边缘计算终端提升 63.0%, 本文提出的识别算法可进一步满足视频流实时推理检测的要求。

## 参考文献

- [1] 李琼,孔宝华,范静华,等.应用TaqMan探针实时荧光定量PCR技术早期检测稻瘟病[J].植物病理学报,2011,41(2):118-123.  
LI Qiong, KONG Baohua, FAN Jinghua, et al. Application of TaqMan probe real-time fluorescence quantitative PCR for early detection of rice blast disease [J]. Acta Phytopathologica Sinica, 2011, 41(2): 118 - 123. (in Chinese)
- [2] 齐龙,蒋郁,李泽华,等.基于显微图像处理的稻瘟病菌孢子自动检测与计数方法[J].农业工程学报,2015,31(12):186-193.  
QI Long, JIANG Yu, LI Zehua, et al. Automatic detection and counting method of rice blast fungus spores based on microscopic image processing [J]. Transactions of the CSAE, 2015, 31(12): 186 - 193. (in Chinese)
- [3] YANG N, YU J, WANG A, et al. A rapid rice blast detection and identification method based on crop disease spores' diffraction fingerprint texture [J]. Journal of the Science of Food and Agriculture, 2020, 100(9): 3608 - 3621.
- [4] 刘潭,李子默,冯帅,等.基于LMPSO-SVM的高光谱水稻稻瘟病害分级检测[J].农业机械学报,2023,54(11):208-216.  
LIU Tan, LI Zimo, FENG Shuai, et al. Classification detection of hyperspectral rice blast disease based on LMPSO-SVM [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 208 - 216. (in Chinese)
- [5] ZHAO G, QUAN L, LI H, et al. Real-time recognition system of soybean seed full-surface defects based on deep learning [J]. Computers and Electronics in Agriculture, 2021, 187: 106230.
- [6] 刘佳辉,刘强,李彤召.基于国产芯片和RTOS的农业病虫害检测系统[J].物联网技术,2023(2):33-34,39.  
LIU Jiahui, LIU Qiang, LI Tongzhao. Agricultural pest and disease detection system based on domestic chip and RTOS [J]. Internet of Things Technologies, 2023(2):33 - 34,39. (in Chinese)
- [7] QIU J, SONG S, WANG Y, et al. Going deeper with embedded FPGA platform for convolutional neural network [C] // The 2016 ACM/SIGDA International Symposium. ACM, 2016.
- [8] AMD Inc. DPUCZDX8G for Zynq UltraScale + MPSoCs product guide (PG338). AMD 自适应计算文档门户 [EB/OL]. [https://docs.xilinx.com/r/en-US/pg338-dpu/Introduction?tocId=3xsG16y\\_QFTWvAJKHBisEw](https://docs.xilinx.com/r/en-US/pg338-dpu/Introduction?tocId=3xsG16y_QFTWvAJKHBisEw).
- [9] LUO Y, CAI X, QI J, et al. FPGA-accelerated CNN for real-time plant disease identification [J]. Computers and Electronics in Agriculture, 2023, 207: 107715.
- [10] 资彩飞,曹志勇,许佳俊,等.基于深度学习的水稻稻瘟病识别研究[J].现代农业科技,2022(1):111-113,118.  
ZI Caifei, CAO Zhiyong, XU Jiajun, et al. A study on rice blast disease recognition in rice based on deep learning [J]. Modern Agricultural Science and Technology, 2022(1): 111 - 113,118. (in Chinese)
- [11] 路阳,郭丹,沈贺,等.基于深度学习的水稻叶部病害识别方法研究[J].信息记录材料,2018,19(12):177-179.  
LU Yang, GUO Dan, SHEN He, et al. Research on a deep learning-based method for recognizing leaf diseases in rice [J]. Journal of Information Recording Materials, 2018, 19(12): 177 - 179. (in Chinese)
- [12] 朱红春,李旭,孟炀,等.基于Faster R-CNN网络的茶叶嫩芽检测[J].农业机械学报,2022,53(5):217-224.  
ZHU Hongchun, LI Xu, MENG Yang, et al. Tea shoot detection based on Faster R-CNN network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5): 217 - 224. (in Chinese)
- [13] 刘莫尘,高甜甜,马宗旭,等.基于MSRCR-YOLOv4-tiny的田间玉米杂草检测模型[J].农业机械学报,2022,53(2):246-255,335.  
LIU Mochen, GAO Tiantian, MA Zongxu, et al. Target detection model of corn weeds in field environment based on MSRCR algorithm and YOLO v4 - tiny [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 246 - 255, 335. (in Chinese)
- [14] 李书琴,陈聪,朱彤,等.基于轻量级残差网络的植物叶片病害识别[J].农业机械学报,2022,53(3):243-250.  
LI Shuqin, CHEN Cong, ZHU Tong, et al. Plant leaf disease recognition based on lightweight residual networks [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 243 - 250. (in Chinese)
- [15] 王泽钧,马凤英,张瑜,等.基于注意力机制和多尺度轻量型网络的农作物病害识别[J].农业工程学报,2022,38(增刊1):176-183.  
WANG Zejun, MA Fengying, ZHANG Yu, et al. Crop disease recognition based on attention mechanism and multiscale lightweight networks [J]. Transactions of the CSAE, 2022, 38(Supp. 1): 176 - 183. (in Chinese)
- [16] HE K, GKIOXARI G, PIOTR D, et al. Mask R-CNN [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2020, 42(2):386-397.
- [17] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: common objects in context [C] // Computer Vision-ECCV 2014: 13th European Conference, Proceedings, Part V 13. Springer International Publishing, 2014: 740 - 755.
- [18] RUSSELL C B, TORRALBA A, MURPHY P K, et al. LabelMe: a database and web-based tool for image annotation [J]. International Journal of Computer Vision, 2008, 77(1-3):157 - 173.
- [19] SHAFIQ M, GU Z. Deep residual learning for image recognition: a survey [J]. Applied Sciences, 2022, 12(18): 8972.

(下转第314页)

- [20] BODENHOFER U, BONATESTA E, HOREJS-KAINRATH C, et al. MSA: an R package for multiple sequence alignment [J]. *Bioinformatics*, 2015, 31(24): 3997–3999.
- [21] ZHANG Z, SABUNCU M. Generalized cross entropy loss for training deep neural networks with noisy labels[J]. *Advances in Neural Information Processing Systems*, 2018, 31: 8792–8802.
- [22] 梁建安, 刘斌, 梁美彦, 等. 基于彩色偏振图像的 HSV 空间目标增强方法[J]. *应用光学*, 2023, 44(3): 548–555.  
LIANG Jian'an, LIU Bin, LIANG Meiyuan, et al. Target enhancement method in HSV color space based on color polarized image[J]. *Journal of Applied Optics*, 2023, 44(3): 548–555. (in Chinese)
- [23] WANG X, KONG T, SHEN C, et al. Solo: segmenting objects by locations [C] // Computer Vision-ECCV 2020: 16th European Conference, 2020: 649–665.
- [24] WANG X, ZHANG R, KONG T, et al. Solov2: dynamic and fast instance segmentation[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 17721–17732.
- [25] FANG Y, YANG S, WANG X, et al. Instances as queries[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 6910–6919.
- [26] YUE Y, FINLEY T, RADLINSKI F, et al. A support vector method for optimizing average precision[C] // Proceedings of the 30th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, 2007: 271–278.

(上接第 304 页)

- [20] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018.
- [21] 何东宇, 朱荣光, 范彬彬, 等. 倒置残差网络结合注意力机制的掺假羊肉分类检测系统构建[J]. *农业工程学报*, 2022, 38(20): 266–275.  
HE Dongyu, ZHU Rongguang, FAN Binbin, et al. Construction of a classification detection system for adulterated mutton by inverted residual network combined with attention mechanism[J]. *Transactions of the CSAE*, 2022, 38(20): 266–275. (in Chinese)
- [22] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[J]. IEEE Computer Society, 2017, 106(1): 936–944.
- [23] 马钦, 万传峰, 卫建, 等. 基于 U-Net 和特征金字塔网络的秸秆覆盖率计算方法[J]. *农业机械学报*, 2023, 54(1): 224–234.  
MA Qin, WAN Chuanfeng, WEI Jian, et al. Calculation method of straw coverage based on U-Net network and feature pyramid network[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(1): 224–234. (in Chinese)
- [24] GUO C, FAN B, ZHANG Q, et al. AugFPN: improving multi-scale feature learning for object detection[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020.
- [25] KEMAL O, BARIS C, EMRE A, et al. Rank & sort loss for object detection and instance segmentation[C] // ICCV 2021 Oral, 2021.
- [26] 孟浩, 刘强. 基于 FPGA 的卷积神经网络训练加速器设计[J]. *南京大学学报(自然科学版)*, 2021, 57(6): 1075–1082.  
MENG Hao, LIU Qiang. Design of FPGA-based training gas pedal for convolutional neural networks[J]. *Journal of Nanjing University (Natural Science)*, 2021, 57(6): 1075–1082. (in Chinese)
- [27] XU Z H, LI J X, DENG S Y, et al. Optimization of real-time detection and classification model for plant leaf diseases based on TensorRT[J]. *Computer Systems and Applications*, 2023, 32(2): 94–101.