

基于 YOLOv8 轻量化的农作物病害检测算法

彭和平¹ 高一峰¹

PENG Heping GAO Yifeng

摘要

针对农作物病害识别存在算法参数量大、计算速度慢和现有公开数据集少等问题,文章提出了一种基于改进 YOLOv8 的目标检测算法。首先,创建了 Mydataset 农作物病害数据集,填补了算法模型在数据集方面的不足。其次,引入了快速神经网络(faster neural networks, FasterNet)轻量化网络模块,大幅减少了模型的参数量和计算量,使得算法更适应低计算能力的环境。同时,采用双向特征金字塔网络(bi-directional feature pyramid network, BiFPN)的特征融合结构,不仅提高了模型的特征融合效率,还进一步降低了参数量,进而显著提升了模型的检测精度和性能。此外,通过引入可变形大内核注意力机制(deformable large kernel attention, D-LKA Attention),扩大了模型的感受野,加强了全局特征的捕捉和局部特征的细化提取,实现了在降低参数量和 FLOPs(floating point operations)的同时提高检测效果的目标。实验结果表明,在 Mydataset、VOC-2007 和 Vehicles 三组数据集上,与原始 YOLOv8 模型相比,YOLOv8-self 在 Mydataset 数据集上,参数量下降了约 20.3%,精准度提升 0.04%,平均精度均值(mean average precision IOU=0.5~0.95, mAP@0.5:0.95)提升了 3.7%,模型的处理帧速(frames per second, FPS)提升了 4%。在 VOC-2007 和 Vehicles 数据集上的检测精度也有类似的提升。同时,实验结果也证明在对于文章提出常见的 12 种农业病害(豆角叶斑、大豆锈病、草莓角斑病、草莓果肉腐烂、草莓粉状叶霉病、草莓花枯萎病、草莓灰霉病、草莓叶斑、草莓白粉果、番茄病、番茄蜘蛛螨、番茄叶霉病)识别任务中,优化后的算法具有更简约、更精准以及更强的泛化性能,能够适应硬件设备条件较差的环境,更适用于农作物病害的检测任务。

关键词

YOLOv8; 算法; 智慧农业; 目标检测; 轻量化网络; 农作物病害

doi: 10.3969/j.issn.1672-9528.2025.04.004

0 引言

农业病害不仅会阻碍作物正常生长,导致产量降低、品质下降,更严重威胁着国家粮食安全。尽管我国化学农药使用量已实现“负增长”,但每年防治的土地面积依然高达 $5.6 \times 10^8 \text{ hm}^2$,是耕地面积的 4 倍^[1]。即便如此,每年仍损失粮食 1 600 万吨。传统的病害防治方法依赖人工或半自动化,存在主观性、消耗人力物力且缺乏普适性,无法满足现代农业对高效低成本防护的需求^[2-3]。因此,随着深度学习和计算机视觉的快速发展,以及国家对智慧农业的支持,采用科学的防护措施已成为提升农业效率和保障粮食安全的关键。

在现代农业技术中,深度学习目标检测被广泛应用,并随着科技的发展不断提升。典型的双阶段检测模型 R-CNN(region-convolution neural networks)系列^[4-5]引入了区域建议网络(RPN),该网络能够生成图像中的候选目标区域,并通过分类器和回归器进行目标检测,从而实现较高的准确性。赵越等人^[6]基于 TensorFlow 平台,使用 Faster R-CNN 模型对马铃薯叶片进行病害检测,采用图像增广技术提高了训练数据的多样性。通过迁移学习,该模型使用 COCO 数据集的预训练权重,最终达到了 99.5% 的检测精度,为马铃薯病害的快速诊断提供了支持。Chen 等人^[7]提出将 K-means 聚类算法嵌入到 Diou-NMS 中,应用于杨梅树单木检测,但该方法需要多次实验来确定最佳阈值,训练时间较长,操作复杂。陈柯屹等人^[8]针对小体积棉花顶芽识别问题,提出了一种以 RegNetX-6.4GF 为主干网络的 Faster

1. 江汉大学智能制造学院 湖北武汉 430056

[基金项目] 国家自然科学基金项目(52075222)

R-CNN 模型，经过改进后，模型精度比原始模型提高了 7.3 个百分点。

尽管 R-CNN 系列在准确性方面表现优秀，但由于其基于双阶段检测模型，网络体积较大、检测时间较长，难以满足实时检测需求。与双阶段模型不同，单阶段目标检测算法通过一次性检测直接获得目标分类和边界框，无需生成候选区域，因此检测速度更快。YOLO 系列神经网络因其出色的计算速度和准确率，在计算机视觉领域的目标识别任务中广泛应用^[9-10]。Li 等人^[11]基于 YOLOv7 设计了 YOLOv7-Litchi 模型，在复杂背景下，荔枝的 mAP 达到了 98.6%。高新阳等人^[12]通过引入轻量化主干网络改进 YOLOv5，用于柑橘的识别，显著降低了模型的参数量和内存占用，提升了识别速度和定位精度。张俊宁等人^[13]将注意力机制与 YOLO 模型结合，提高了物体识别的准确性和效率。

综上所述，YOLO 系列是当前主流的单阶段目标检测模型。本文基于 YOLOv8 进行研究，旨在解决其在户外农作物病害检测中面临的参数量大和计算速度慢的问题。

1 数据集制作

YOLOv8 模型的目标识别依赖于神经网络训练，数据集的规模对模型的准确性和鲁棒性有重要影响。数据集过大会导致训练时间增加、计算资源消耗大，并产生冗余数据；数据集过小则容易导致过拟合和泛化能力差。因此，高质量的数据集能够提升模型的准确性，缩短训练时间，降低硬件需求。

本文使用的数据集取自 roboflow.com，包含 12 种农作物病害（豆角叶斑、大豆锈病、草莓角斑病、草莓果肉腐烂、草莓粉状叶霉病、草莓花枯萎病、草莓灰霉病、草莓叶斑、草莓白粉果、番茄病、番茄蜘蛛螨、番茄叶霉病），共计 5 483 张 640 px×640 px 的 JPG 格式图片。由于各类别图片数量不均，可能导致识别偏差。为提升模型的泛化能力和性能，本文采用 3 种数据增强方法：调整色彩（灰度）、仿射变换和高斯噪声，以丰富数据集并提高识别准确性。如图 1 所示。




图 1 数据增强之后的效果对比图

通过上述 4 种方法将数据集增加到 13 159 张图片。图片的标注格式为 YOLO 格式。其两者数据集的对比如表 1 所示。

表 1 原始数据与数据增强后的对比

数据集 Dataset	训练 Train	验证 Valid	测试 Test	总计 Total
Mydata	2 904	1 416	1 173	5 493
Mydataset	11 514	1 097	548	13 159

2 检测算法

2.1 网络整体结构

本文基于 YOLOv8 进行轻量化改进，提出适合智慧农业的深度学习神经网络模型 YOLOv8-self，其结构如表 2 所示。针对户外设备维护难度大、成本高的问题，该模型优化了参数量和计算量，以适配移动设备或低配设备的需求。首先，结合 FasterNet 网络模型，显著降低模型复杂度、参数量和 FLOPs；其次，引入 DeformConv 和 BiFPN 模块，增强特征提取能力，进一步减少计算量并提升检测精度。

表 2 YOLOv8-self 网络结构表

层数 Layers	from	参数量 Parameters	模块名称 Models
0	-1	1 600	PatchEmbed_FasterNet
1	-1	4 800	BasicStage
2	-1	8 320	PatchEmbed_FasterNe
3	-1	18 944	BasicStage
4	-1	33 024	PatchEmbed_FasterNe
5	-1	301 056	BasicStage
6	-1	127 472	PatchEmbed_FasterNe
7	-1	281 604	BasicStage
8	-1	154 504	SPFF
9	-1	32 000	Conv
10	-1	0	Upsample
11	[-1, -5]	16 514	BiFPN_Add2
12	-1	168 210	DeformConv
13	-1	8 320	Conv
14	-1	0	Upsample
15	[-1, -3]	4 162	BiFPN_Add2
16	-1	47 250	DeformConv
17	-1	73 984	Conv
18	[-1, -12]	16 514	BiFPN_Add2
19	-1	168 210	DeformConv
20	-1	147 712	Conv
21	[-1, -9]	16 514	BiFPN_Add2
22	-1	168 210	DeformConv
23	[16, 19, 22]	606 196	Detect

在表 2 中，from 表示该层连接的输入层；-1 表示连接的上一层。

2.2 FasterNet 轻量化主干网络

FasterNet^[14] 是一种简单、高效的网络模型，具有低延迟、高吞吐的特点，并提出一种新的部分卷积（partial convolution, PConv）。PConv 优化了在早期 MobileNets^[15]、ShuffleNets^[16] 和 GhostNet^[17] 中通过深度卷积（DWConv）和组卷积（Gconv）减少 FLOPs 但增加内存和运行时间问题。

PConv 通过对部分输入通道进行卷积，保持其余通道不变，以实现连续的内存访问。在保证输入输出通道一致的前提下，有效提取特征，同时大幅减少计算量和内存需求。如图 2 所示。




图 2 PConv 原理图

从而得出 PConv 的 FLOPs 的计算公式为：

$$h \times w \times k^2 \times C_p^2 \quad (1)$$

相较于常规的 Conv 和 DWConv 的计算 FLOPs，当选取 PConv 与经典 Conv 之间的比率为 $r = \frac{C_p}{C} = \frac{1}{4}$ 时，PConv 的 FLOPs 相较于普通的 Conv 缩小了 16 倍。用公式分别表示为：

$$h \times w \times k^2 \times C^2 \quad (2)$$

$$h \times w \times k^2 \times C \quad (3)$$

同时，PConv 也拥有更少的内存访问量，公式为：

$$h \times w \times 2C_p + k^2 \times C_p^2 \approx h \times w \times 2C_p \quad (4)$$

相较于常规 Conv 的内存访问。当 $r = \frac{C_p}{C} = \frac{1}{4}$ 时，PConv 的内存访问量缩小四倍。用公式表示为：

$$h \times w \times 2C + k^2 \times C^2 \approx h \times w \times 2C \quad (5)$$

PConv 相较于 Conv，显著降低了 FLOPs；相比 DWConv 或 GConv，则具有更高的 FLOPs 表现。这意味着 PConv 能够更高效地发挥设备计算能力，同时在空间特征提取方面表现优异。

基于 PConv 的研究，引出 FasterNet 网络模型，其结构如图 3 所示。该网络模型以 PConv 为核心算子，由 FasterNet Block 划分为 4 个阶段，每个阶段前包含一个模块：Embedding 层或 Merging 层。Embedding 层采用步幅为 4 的 4×4 卷积，Merging 层采用步幅为 2 的 2×2 卷积，两者均用于实现空间下采样和通道扩展。每个 FasterNet Block 由 PConv 和 1×1 卷积构成，通过引入倒置残差块能有效减少计算量和参数量，

提升计算效率与性能此外，跳跃连接的设计实现了输入特征的高效重复利用，进一步优化了特征提取。




图 3 FasterNet 网络模型图

在 YOLOv8 模型中替换骨干网络为 FasterNet 后，模型不仅显著降低了参数量和 FLOPs，还提升了检测精度。改进后的 YOLOv8 更加轻量化，在农作物病害检测中表现出更高的准确性和快速性，适合实际应用需求。

2.3 引入 BiFPN 结构

在特征融合过程中，深层网络感受野大、特征表达强，但分辨率低、细节不足；浅层网络感受野小、特征表达弱，但分辨率高、细节丰富。因此，融合不同层次的特征可以充分利用各自优势，提升整体特征表达能力。

YOLOv8 使用 FPN+PAN 进行多尺度特征融合，但由于 PAN 网络中的输入特征已通过 FPN 处理，这可能导致原始特征的丢失，降低了特征融合效率。为了解决这一问题，Tan 等人^[18] 提出了基于 FPN+PAN 结构的改进版——加权特征金字塔网络（BiFPN），通过高效的双向跨尺度连接和加权融合机制，优化了特征融合效果。其网络结构如图 4 所示。




图 4 不同特征网络的机制原理图

从图 4 (a) 可见，FPN 通过自上而下和横向连接进行特征融合；图 4 (b) 中，PAN 通过增加自下而上的路径解决了

FPN 的单向信息流问题；图 4（c）中的 BiFPN 则通过删除贡献较少的单输入节点简化网络结构，并实现双向特征融合。BiFPN 还通过增加输入输出通道，以较低计算成本融合更多特征，并通过多次重复上下路径，提升了特征融合效果，优于 PAN。

BiFPN 在做出双向跨尺度连接的同时也选择了归一化融合，其计算方式为：

$$O = \sum_{i=0} \frac{\omega_i \cdot I_i}{\varepsilon + \sum_{j=0} \omega_j} \quad (6)$$

式中： ω_i 与 ω_j 表示不同的权重学习参数； $\varepsilon = 0.0001$ ，避免数值的不稳定； I_i 表示输入特征。


以图 4（c）为例，假设卷积神经网络有 3~7 级输入特征，第 3 级和第 7 级节点只有一条输入边，是网络的边缘节点，因此特征融合信息较少，可以删除。而第 6 级的中间节点连接第 7 级的输入节点，这样可以保留第 7 级的特征信息同时简化网络结构，提升效率。

总而言之，BiFPN 特征融合结构在减少参数量的同时提升了计算效率，并在准确性上有所提高，成功平衡了参数量、FLOPs 与检测准确度的关系。


2.4 引入 DeformConv 可变形大卷积注意力

传统的 Transformer 模型擅长捕捉长程依赖，但计算成本高且局部特征捕捉能力较弱，限制了其深度和分辨率。Azad 等人^[19]提出的 D-LKA (deformable large kernel attention) 机制，通过结合大卷积核和可变形卷积，既能有效捕捉全局上下文信息，又能适应局部变化，提升了模型的表现。

由图 5（a）（b）对比，D-LKA 在大卷积核的基础上引入了可变形卷积，允许卷积核在不同位置动态调整，从而更好地适应图像形变和复杂结构，提升特征提取的灵活性和准确性。可变形卷积中的偏移量使得卷积在不同位置进行灵活采样，增强了特征捕捉能力。在特征融合方面，D-LKA 结合卷积操作和注意力机制，通过大卷积核和可变卷积的组合，不仅能捕捉全局特征，还能细化局部特征。



(a) LKA



(b) D-LKA

图 5 LKA 与 D-LKA 注意模块的体系结构

D-LKA 模块的公式表示为：

$$\text{Attention} = \text{Conv}_{1 \times 1}(\text{DDW_D_Conv}(\text{DDW_Conv}(F'))) \quad (7)$$

$$\text{Output} = \text{Conv}_{1 \times 1}(\text{Attention} \otimes F) + F \quad (8)$$

式中：特征记为 $F \in \mathbb{R}^{C \times H \times W}$ ， $F' = \text{Gelu}(\text{Conv}(F))$ ； $\otimes$ 为元素积运算。

整体来说，D-LKA 通过优化架构和卷积操作提高了计算效率。关键优化措施包括：使用大卷积核捕捉长程依赖、引入可变形卷积适应形变、采用深度可分离卷积减少计算量、分阶段处理特征减少冗余计算，以及应用多尺度特征融合策略。这些优化共同作用，使得 D-LKA 在保持高效特征提取的同时，显著提升了计算效率。

3 实验结果及分析

3.1 数据集及预处理

为验证本文模型的优越性，本文不仅在农业病害领域进行测试，还使用了 3 组不同领域的数据集进行训练和评估。第一组是前述的通过数据增强处理的 Mydataset；第二组是公开数据集 VOC-2007；第三组是汽车识别领域的 Vehicles 数据集。各数据集的详细信息如表 3 所示。

表 3 三组数据集的详细信息

数据集划分 Dataset	类别 Class	训练 Train	验证 Valid	测试 Test	总计 Total
Mydataset	12	11 514	1 097	548	13 159
VOC-2007	20	2 501	2 510	4 952	9 963
Vehicles	12	2 634	966	458	4 058

3.2 实验环境与参数配置

为确保实验结果的公平性，本文在所有实验中使用了相同的环境参数和模型超参数。具体的实验参数信息如表 4 所示。

表 4 实验环境配置参数

名称 Name	参数 Parameter
操作系统	Linux
CPU	12 vCPU Intel(R) Xeon(R) Platinum 8255C CPU @ 2.50 GHz
GPU	RTX 3090(24 GB) ×1
内存	43 GB
Python	3.8(ubuntu20.04)
Pytorch	1.11.0
Epoch	300
Batchsize	32
图片尺寸	640×640

3.3 评价指标

本文的模型评价指标包括四个方面：精准度（Precision）、mAP@0.5:0.95、参数量（Parameters）和 FPS（Frames Per Second）。精准度衡量模型检测正样本的准确性；mAP@0.5:0.95 提供比 mAP@0.5 更严格的评估标准，反映模型在不同 IoU 阈值下的整体性能；参数量表示模型的复杂度，较大参数量意味着更高的计算和存储成本；FPS 衡量模型处理图像的速度，体现了实时检测能力。通过这些指标，可以全面评估模型的性能和复杂度，便于不同模型的对比分析。

3.4 消融实验

为了验证 YOLOv8 模型优化后的 YOLOv8-self 模型的综合性能，以及各项改进方法的有效性和引入模块之间的协同作用，本文设计了 8 组对比实验。通过这些实验，评估每一步改进的实际效果。具体的实验对比条件如表 5 所示，其中“√”表示该组实验中引入的模块，第一组为 YOLOv8 模型基线。

表 5 消融实验

组号 Group	Faster Net	BiFPN	Deform Conv	参数量 Parameters /10 ⁶	精准度 Precision	mAP@0.5:0.95	FPS
1				3.01	0.921	0.759	456
2	√			2.52	0.908	0.76	470
3		√		2.94	0.910	0.786	442
4			√	20.09	—	—	—
5	√	√		2.68	0.913	0.77	469
6		√	√	2.98	0.914	0.788	459
7	√		√	19.80	—	—	—
8	√	√	√	2.40	0.925	0.788	476

注：在实验的过程中，在单独引入 DeformConv 和引入 FasterNet 和 DeformConv 时，即第 3 组实验和第 7 组实验。

发现参数量和 FLOPs 由于 DeformConv 模块本身计算量的原因而变大，已经不满足本文研究 YOLOv8 轻量化的意义，为节约时间和计算成本，便不考虑该两组的 P、mAP@0.5:0.95 以及 FPS 三个评价指标。

在第 8 组实验中，加入 FasterNet、BiFPN 和 Deform-Conv 模块后，模型在各项评价指标上均表现最佳，相比前 7 组实验，优化效果显著。与基线第 1 组相比，参数量减少了 20.3%，精准度提升了 0.04%，mAP@0.5:0.95 提高了 3.7%，FPS 增加了 4%。结果表明，这 3 个模块的组合在平衡模型复杂度与检测精度方面表现出色，验证了该模型在轻量化的基础上提升了准确度，更加适合智慧农业中的检测任务。

3.5 定量评价

为验证 YOLOv8-self 模型的可行性，本文将其与当前主流的单阶段、双阶段以及轻量化检测模型进行了对比，并在不同数据集和领域中进行了综合评估。

从表 6 可见，YOLOv8-self 相较于 YOLOv8，参数量减少了 20.3%，精准度提升了 0.04%，mAP@0.5:0.95 提高了 3.7%，FPS 增加了 4%。引入 FasterNet、BiFPN 和 Deform-Conv 模块后，YOLOv8-self 在同组实验中表现出明显优势，验证了优化的有效性。此外，YOLOv8-self 对硬件要求低，并且在 12 种农作物病害的检测任务中展现出最高的综合准确率，特别适合低成本或移动端检测，尤其在农作物病害检测中具有较高应用潜力。

表 6 在 Mydataset 数据集不同模型的对比实验

模型 Models	参数量 Parameters /10 ⁶	精准度 Precision	mAP@0.5:0.95	FPS
Faster R-CNN	57.4	0.900	0.742	256
YOLOv5s	7.05	0.910	0.781	356
YOLOv7	23.2	0.906	0.735	387
YOLOv7-tiny	6.04	0.890	0.689	369
YOLOv8	3.01	0.921	0.759	456
YOLOv8-self	2.40	0.925	0.788	476

如表 7 所示，YOLOv8-self 在参数量、精准度和 mAP@0.5:0.95 方面均优于 YOLOv8，表现出更低的复杂度和更高的准确性。在 Mydataset 数据集中，YOLOv8-self 参数量最小，mAP@0.5:0.95 最高，显示了该模型在实际应用中的高可行性。在 VOC-2007 和 Vehicles 数据集中，YOLOv8-self 相比 YOLOv8，参数量减少约 20%，精度显著提升，验证了模型优化的有效性和较强的泛化能力。此外，YOLOv8-self 在 Mydataset 数据集中的 12 种农作物病害检

测任务中表现最佳，进一步证明了该模型在农业病害检测中的优越性。

表 7 YOLOv8 与 YOLOv8-self 在不同数据集上的对比实验

数据集 Dataset	模型 Models	参数量 Parameters	精准度 Precision	mAP@ 0.5:0.95	FPS
Mydataset	YOLOv8	3013188	0.921	0.759	456
	YOLOv8-self	2405120	0.925	0.788	476
VOC-2007	YOLOv8	3014748	0.501	0.285	456
	YOLOv8-self	2406680	0.512	0.294	476
Vehicles	YOLOv8	3014188	0.490	0.315	456
	YOLOv8-self	2406120	0.521	0.325	476

4 结论

为实现农业病虫害的户外快速精准检测，本文基于 YOLOv8 网络模型进行优化，提出一种轻量化的网络模型 YOLOv8-self。

（1）数据集构建：自制数据集 Mydataset，其中包含 12 类常见农作物病害，并通过在相同数据集上使用不同算法进行对比，以及在不同领域的数据集上应用相同算法进行的多维验证，证明数据的可行性。

（2）模型优化：通过引入 FasterNet、BiFPN 特征融合和 DeformConv 模块，降低网络复杂度。实验表明，模型参数量减少 20.3%，精度提升 0.04%，mAP@0.5:0.95 提升 3.7%，FPS 提升 4%。准确率高于主流模型，适合低成本检测，满足农业户外硬件要求低的需求。

YOLOv8-self 能够降低硬件需求、减少人力和时间成本，提升工作效率和粮食保护效果。未来可在注意力机制、检测头和小目标识别等方面进一步优化，以提升农业病害检测性能。

参考文献：

[1] 岳喜申. 深度学习在农作物病害识别中的研究进展[J]. 安徽农学通报, 2024, 30 (6):100-103.

[2] 刘文德, 代玉立, 邵小龙, 等. 我国主要农作物病害灾变机制与综合防控研究进展:2018 年—2022 年[J]. 植物保护, 2023, 49 (5):1-31.

[3] 苏丹, 邓永卓. 农作物病害图像识别研究进展和存在问题[J]. 天津农学院学报, 2023, 30 (3): 75-79.

[4] GIRSHICK R, DONAHUE J, DARRELL T, et al. Region-based convolutional networks for accurate object detection and segmentation[J]. IEEE transactions on

pattern analysis and machine intelligence, 2016, 38(1): 142-158.

[5] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1137-1149.

[6] 赵越, 赵辉, 姜永成, 等. 基于深度学习的马铃薯叶片病害检测方法 [J]. 中国农机化学报, 2022, 43(10):183-189.

[7] CHEN Y L, XU H L, ZHANG X J, et al. An object detection method for bayberry trees based on an improved YOLO algorithm[J]. International journal of digital earth, 2023, 16(1): 781-805.

[8] 陈柯屹, 朱龙付, 宋鹏, 等. 融合动态机制的改进型 Faster R-CNN 识别田间棉花顶芽 [J]. 农业工程学报, 2021, 37(16):161-168.

[9] WU K J, ZHANG J T, YIN X C, et al. An improved YOLO model for detecting trees suffering from pine wilt disease at different stages of infection [J]. Remote sensing letters, 2023, 14(2): 114-123.

[10] YANG S Z, WANG W, GAO S, et al. Strawberry ripeness detection based on YOLOv8 algorithm fused with LW-swin transformer[J].Computers and electronics in agriculture, 2023, 215: 108360.

[11] LI C, LIN J Q, LI Z, et al. An efficient detection method for litchi fruits in a natural environment based on improved YOLOv7 Litchi [J]. Computers and electronics in agriculture, 2024, 217: 108605.

[12] 高新阳, 魏晟, 温志庆, 等. 改进 YOLOv5 轻量级网络的柑橘检测方法 [J]. 计算机工程与应用, 2023, 59(11): 212-221.

[13] 张俊宁, 毕泽洋, 闫英, 等. 基于注意力机制与改进 YOLO 的温室番茄快速识别 [J]. 农业机械学报, 2023, 54(5): 236-243.

[14] 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). Piscataway: IEEE, 2023:12021-12031.

[15] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2019: 1314-1324.

（下转第 30 页）

- [8] FENG W S, QIAO P, CHEN Y J. Fast and accurate poisson denoising with trainable nonlinear diffusion[J]. IEEE transactions on cybernetics, 2018, 48(6): 1708-1719.
- [9] 许玉婷, 吴志芳, 王强, 等. 基于剪切波变换的辐射图像泊松噪声降噪技术研究 [J]. 原子能科学技术, 2022, 56(3): 577-584.
- [10] MAKITALO M, FOI A. Optimal inversion of the generalized anscombe transformation for poisson-gaussian noise[J]. IEEE transactions on image processing, 2013,22(1):91-103.
- [11] MAKITALO M, FOI A. A closed-form approximation of the exact unbiased inverse of the anscombe variance-stabilizing transformation[J]. IEEE transactions on image processing, 2011,20(9):2697-2698.
- [12] GOU Y B, HU P, LV J C, et al. Multi-scale adaptive network for single image denoising[C]//NIPS'22: Proceedings of the 36th International Conference on Neural Information Processing Systems. NewYork: ACM, 2022: 14099-14112.
- [13] 汤勇峰. 基于多尺度卷积神经网络的图像去噪方法研究 [J]. 无线互联科技, 2022, 19(24):154-156.
- [14] 许雪, 郭业才, 李晨. 基于卷积神经网络的多尺度特征融合去噪算法 [J]. 计算机与数字工程, 2023, 51(10): 2400 - 2404.
- [15] 李晨, 李雪婷, 李红旭, 等. 融合多尺度特征的遥感图像去噪方法 [J]. 电光与控制, 2024, 31(6): 74-80.
- [16] BURGER H C, HARMELING S. Improving denoising algorithms via a multi-scale meta-procedure[C]// DAGM'11: Proceedings of the 33rd international conference on Pattern recognition.NewYork:ACM,2011:206-215.
- [17] LEBRUN M, COLOM M, MOREL J M. Multiscale image blind denoising[J].IEEE transactions on image processing, 2015, 24(10): 3149-3161.
- [18] DONG W S, WANG P Y, YIN W T, et al. Denoising prior driven deep neural network for image restoration[J].IEEE transactions on pattern analysis and machine intelligence, 2019, 41(10): 2305-2318.
- [19] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]// Proceedings Eighth IEEE International Conference on Computer Vision(ICCV). Piscataway: IEEE, 2001, 2: 416.
- [20] REMEZ T, LITANY O, GIRYES R, et al. Class-aware fully convolutional gaussian and poisson denoising[J]. IEEE transactions on image processing, 2018, 27(11): 5707-5722.
- [21] ZHANG L, WU X L, LI X, et al. Color demosaicking by local directional interpolation and nonlocal adaptive thresholding[J]. Journal of electronicimaging, 2011, 20(2): 23016.

【作者简介】

赵俊普(1998—), 男, 河南驻马店人, 硕士研究生, 研究方向: 图像处理。

张小波(1979—), 男, 陕西咸阳人, 博士, 教授、硕士生导师, 研究方向: 图像处理和自然语言处理。

(收稿日期: 2024-11-20)

(上接第 23 页)

- [16] MA N N, ZHANG X Y, ZHENG H T,et al. ShuffleNetV2: practical guidelines for efficient CNN architecture design[DB/OL].(2018-07-30)[2024-05-19].https://doi.org/10.48550/arXiv.1807.11164.
- [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). Piscataway: IEEE, 2020:1580-1589.
- [18] TAN M X, PANG R M, LE Q V. EfficientDet: scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020:10778-10787.
- [19] AZAD R, NIGGEMEIER L, HUTTEMANN M, et al. Beyond self-attention: deformable large kernel attention for medical image segmentation[C]//2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Piscataway: IEEE, 2024:1276-1286.

【作者简介】

彭和平(1966—), 男, 湖北武汉人, 博士, 教授, 研究方向: 公差设计基础理论与方法、精度控制技术与系统开发等。

高一峰(2001—), 男, 湖北荆州人, 硕士研究生, 研究方向: 深度学习。

(收稿日期: 2024-12-12)