

DOI: 10.13733/j.jcam.issn.2095-5553.2025.09.046

郭佳希, 姚竞发, 滕桂法. 广域作物种植种类解析技术[J]. 中国农机化学报, 2025, 46(9): 352—360

Guo Jiaxi, Yao Jingfa, Teng Guifa. Analysis technology of wide area crop planting types [J]. Journal of Chinese Agricultural Mechanization, 2025, 46(9): 352—360

广域作物种植种类解析技术^{*}

郭佳希^{1, 2}, 姚竞发^{3, 4}, 滕桂法^{1, 2}

(1. 河北农业大学信息科学与技术学院, 河北保定, 071000; 2. 河北农业大学河北省农业大数据重点实验室, 河北保定, 071000; 3. 河北软件职业技术学院, 河北保定, 071000; 4. 河北省高校智能互联装备与多模态大数据应用技术研发中心, 河北保定, 071000)

摘要: 实时精准获取田间土地信息是农业管理部门有效落实种植计划与监管的重要手段与关键环节。为克服基于无人机影像的农田分类中面临的精度不足、边缘模糊以及效率低下等问题, 融合无人机图像处理及深度学习技术, 改进 DeepLabV3+ 网络模型。首先引入轻量级网络 MS—MobileNetV2 替代原有主干, 显著提升识别效率; 其次集成 ECANet 模块, 有效抑制背景干扰因素, 使模型专注于作物信息的提取; 最后调整 ASPP 的膨胀率, 级联不同尺度的信息, 增强特征抓取能力。选取蠡县周边农田作为研究区域, 利用无人机正射影像构建数据集, 进行对比试验。结果表明: 所提方法在玉米、山药、荒地、乔木、菜地的分类精度上分别提高 0.7%、1.15%、5.04%、2.59%、0.95%, 并且减少 87.8% 的参数量和 50.5% 的训练用时。

关键词: 广域作物; 无人机; 深度分离卷积; 编解码结构; 特征融合; 高效通道注意力

中图分类号: S15; TP391.4 **文献标识码:** A **文章编号:** 2095-5553 (2025) 09-0352-09

Analysis technology of wide area crop planting types

Guo Jiaxi^{1, 2}, Yao Jingfa^{3, 4}, Teng Guifa^{1, 2}

(1. College of Information Science and Technology, Hebei Agricultural University, Baoding, 071000, China; 2. Hebei Key Laboratory of Agricultural Big Data, Hebei Agricultural University, Baoding, 071000, China; 3. Hebei Software Institute, Baoding, 071000, China; 4. Hebei Province Intelligent Interconnection Equipment and Multimodal Big Data R & D Center, Baoding, 071000, China)

Abstract: The real-time and accurate acquisition of field land information was crucial for agricultural management departments to implement crop planting plans and monitor agricultural activities. However, the existing methods faced challenges such as low accuracy, unclear edge classification and low efficiency in recognizing agricultural land features based on drone RGB images. To address these issues, an improved version of the DeepLabV3+ network was proposed in this study. This approach integrated multiple technical fields, including drone image acquisition, image processing and deep learning algorithms. Firstly, recognition efficiency was enhanced by replacing the backbone with a lightweight network, MS—MobileNetV2. Secondly, the ECANet module was incorporated to suppress background interference and focus on crop information. Finally, the ASPP expansion rate was adjusted to cascade different scales of information, thereby enhancing feature capture. A dataset was constructed by using drone orthophoto images of farmland around Li County, Baoding City, and comparative experiments were conducted on its detection performance. The experimental results showed that this method improved the classification accuracy of corn, yam, wasteland, trees, vegetable fields, and greenhouses by 0.7%, 1.15%, 5.04%, 2.59%, 0.95%, respectively, and reduced the number of parameters by 87.8% and training time by 50.5%.

Keywords: wide area crop; drones; deep separation convolution; encode and decode structure; feature fusion; efficient channel attention

收稿日期: 2024 年 4 月 15 日 修回日期: 2024 年 6 月 5 日

^{*} 基金项目: 国家自然科学基金项目(U20A20180); 河北省重点研发计划项目(21327405D); 中国高校产学研创新基金资助课题(2021LDA10005); 保定市基础研究专项项目(2472P016)

第一作者: 郭佳希, 男, 1992 年生, 河北保定人, 硕士研究生; 研究方向为人工智能和机器视觉。E-mail: 807289958@qq.com

通讯作者: 姚竞发, 男, 1983 年生, 河北衡水人, 博士, 讲师; 研究方向为人工智能与数字农业、智能农机作业路径规划等。E-mail: yaojingfa@hbsi.edu.cn

0 引言

改革开放以来,我国的经济、工业化以及城市化进程对土地利用格局产生了深远影响^[1]。近年来,我国农业生产结构正处于转型的关键时期,保障粮食安全是国家的基本政策之一,而农作物是实现粮食安全的重要物质基础^[2]。因此,选择优质优良品种的农作物种植非常重要。在此背景下,精准获取农作物种植情况不仅是科学规划农业发展策略的前提,更是分析作物生长状态、优化资源配置的重要依据。因此,快速准确地进行农作物分类、获取种植面积等信息具有极高的价值和紧迫性^[3]。

农作物分类多是借助卫星遥感技术或无人机(UAV)技术^[4,5]。遥感技术以其快速、全面、无侵入性和客观性的优势,能够高效地收集和分析作物种类、生产量等关键信息。GeoEye—1 和 Worldview2 等卫星^[6]能够捕获地球表面约 1 m 空间分辨率的高清图像,但在精细尺度作物识别方面存在局限。受限于运行轨道和时延,卫星无法保证实时性,容易被云层遮盖且成本较高。相比于卫星,UAV 展现了较高的灵活性,能够以较低的成本获得厘米量级的高分辨率图像,其具备出色的实时性,成本低、作业效率高,且不易被云层影响,为数据采集奠定了坚实基础。无人机遥感技术弥补了卫星遥感在作物信息采集方面的限制,迅速发展成为田块尺度作物信息采集的主流技术。

当前基于遥感进行农田作物分类研究主要聚焦于机器学习和深度学习两大领域。如 Kang 等^[6]采用逐步判别分析(SDA)和随机森林(RF)算法对 GF—6 卫星拍摄的衡水市周边红边光谱数据进行深入分析,旨在实现土地利用和作物类型的精准分类。然而,机器学习模型的性能高度依赖于特征的选择,这就需要深厚的专家知识和对分类地区的长期经验。此外手工提取大量特征不仅是一项复杂的任务,还可能因为人为因素的介入而影响分类的准确性。基于卷积神经网络(CNN)的深度学习模型相比于基于机器学习的分类模型展现出显著优势。CNN 凭借其多层非线性网络结构,能够自动提取大量特征,并具备执行多标签分类的固有能力,从而极大地提高了分类的准确性和效率。如 Chew 等^[7]利用 VGG—16 模型识别了无人机在卢旺达收集的 RGB 图像中的 3 种不同的粮食作物(香蕉、玉米和豆类)。Yang 等^[8]提出了一种多层卷积神经网络模型,用于研究水稻作物的物候学,可以直接从 RGB 图像中识别水稻主要生育期。Bah 等^[9]通过融合经典 CNN 和霍夫变换,设计了一种名为 CRowNet 的新 CNN 架构,用于从无人机图像中检测玉米田的作物行。Kitano 等^[10]使用 U—Net 架

构根据无人机捕获的 RGB 图像对农田中的玉米植株进行识别和计数。如 Huang 等^[11]对比了使用机器学习和基于 AlexNet、VGGNet、ResNet 和 GoogLeNet 的 FCN 架构进行稻田杂草测绘。

CNN 在作物分类领域取得了显著进展,而无人机的快速发展更是为图像识别和作物分类研究注入了新的活力。然而,由于农田作物在无人机图像中的特征相似性较高,传统的标准 CNN 架构往往难以准确提取显著特征以正确分类相似作物。为此,经过优化的 DeepLab 系列模型^[12-14]应运而生,以满足对无人机鸟瞰田块图像的精细分割需求。其中最新的 DeepLabV3+ 模型^[15]以其卓越的分割效果,被广泛认为是图像处理领域的新里程碑。如郭金等^[16]将 Transformer 引入 DeepLab 模型,提高了对容易错分的 3 种作物(甘蔗、玉米和香蕉)的无人机拍摄样本的分类精度。张志博等^[17]提出了 DeepLabV3+_BA 网络,提高了农田中地物分类精度。张泉等^[18]构建了优化的 DeepLab 网络,对居民区植物分类的准确度、精确度均有所提升。

尽管原始的 DeepLabV3+ 网络在捕获多维度特征以及提升边缘分类性能上表现出色,但在处理小规模地物时,其存在工作效率偏低、参数规模偏大以及分类精度有待进一步提升等问题,仍具有优化与改进空间,值得进一步探索与研究。因此,针对田块土地解析任务,本文提出基于 DeepLabV3+ 改进的 ME—DeepLabV3+ 模型,通过同构网络架构改进、参数调优、数据增强以及模型融合等一系列技术手段,更好地适应实际应用场景,实现更为精准的多类别地物分类,为农田管理提供有力支持。

1 研究区及数据来源

1.1 研究区概况

研究区位于河北省保定市蠡县,经度约 115.515°,纬度约 38.554°。该区位于中国华北平原,年均降水量 519.8 mm,年均气温 12.7℃,昼夜温差大,光照充足,日照时数 2 444.6 h,属于温带大陆性季风气候。进行航拍时,该区域内主要作物物候特征:玉米处于乳熟期,山药处于块茎膨大期。

1.2 数据获取

2023 年 8 月 29 日上午,在保定市蠡县周边区域田地拍摄。航拍时,该地区主要植被有玉米、山药、乔木以及各种蔬菜。玉米种植面积最大,株距密集,茎上有宽大叶片,能将土地完全覆盖。山药为当地特色经济作物,以白嘴山药和紫山药种植数量最多。山药种植时需要搭架引蔓,其叶片为长三角形,叶片根部有左右对称的弧形。乔木以白杨树、核桃树和桃树

为主,乔木的特征为树体高大、枝叶层次丰富。种植蔬菜的土地往往成列裸露,蔬菜整齐排列。荒地的图像特征为土地裸露不规则,其上有无规律分布的杂草。

飞行平台为大疆 DJI inspire 1 raw 四旋翼无人机系统,最大水平飞行速度为 79 km/h,最长飞行时间为 18 min,可拆式三轴稳定云台,可转动范围水平为 320°,俯仰角为 $-90^{\circ} \sim +30^{\circ}$ 。影像传感器为 FC350 可见光 RGB 相机,有效像素为 1 240 万,ISO 范围 100~1 600(照片),机载内存 64 GB。于满足航摄要求的时间段拍摄,天气晴日光温和,地面微风。参考张志博等^[17]完成的最合适飞行高度讨论,本文设计飞行高度为 150 m,此高度足以满足航片精度要求。设定航向重叠度与旁向重叠度均为 70%。飞行区域宽约 1.2 km、长约 1.5 km,共拍摄 3 691 幅原始相片。DJI inspire 1 raw 拍摄的照片自带 POS 数据,将以上数据导入软件 PhotoScan 1.4.5 中进行对齐定位建立密集点云,然后生成纹理制作出数字正射影像图。研究区正射影像、高空局部航片如图 1 所示。



图 1 数字正射影像图

Fig. 1 Digital orthophoto map

1.3 数据预处理

使用 Labelme 工具将图像按比例压缩裁剪成 512 像素×512 像素尺寸的小样本。选择 3 000 幅代表性的样图,根据采集点实际地表物体划分类目,包含玉米、山药、菜地、乔木、大棚、荒地。利用支持多种标注类型(多边形、圆形)的 Labelme 5.3.1,逐像素点对选择的样本进行标注。图像中灌木所占比例较小,所以未被标注;图中大棚塑料膜损坏或者未遮盖均标注为大棚,大棚的间隙标注为背景,若间隙种植了蔬菜则标记为菜地。样本采样图如图 2 所示。




图 2 样本采样图

Fig. 2 Sample sampling chart

为确保深度学习模型能够从多样化的特征中学习并提升其面对复杂场景的鲁棒性,鉴于深度学习对样

本数量的需求,采用数据增强技术对精选出的样本图像进行扩充。为防止模型在训练过程中过度拟合,使用不同的方法对标签图像进行数据增强,包括旋转 180°、上下翻转、水平翻转以及调整图像的亮度、锐度和饱和度等。针对占比较少的大棚类标签,进行重点增强以解决样本平衡性问题。此外,为确保数据质量,手动筛选并删除存在空白、残影、畸变等不良样本以及重合度较高的图像。最终得到数据集 5 000 幅。将数据集采用 8:2 的方式随机划分样本集和验证集,以确保模型在训练过程中既能够充分学习特征,又能有效地评估模型的性能。

2 研究方法

2.1 深度学习语义分割算法

在图像视觉领域,图像分类和语义分割有所区别。图像分类是将整个图像标记为单个类别,输出是图像所属类别的概率值。相比之下,语义分割是一种基于像素级别的分类任务,对输入样本进行细致的划分,每个点都被归类到特定的类型中,因此也被称为端到端的输入和输出任务。通常使用卷积神经网络实现语义分割。在经典的卷积神经网络中,全连接层是必不可少的组成部分,但它们会带来大量的参数,使得网络变得非常庞大。为解决这个问题,全卷积神经网络被引入其中,它将全连接层全部换成反卷积层,从而显著减少参数量。

选用 4 种经典的语义分割模型(FCN、PSPNet、UNet、DeepLabV3+) ^[19-21] 对研究区土地利用进行精准分类。这 4 种模型均采用了编码器—解码器的结构。其中,编码器主要由卷积层、池化层以及激活函数等部件构成,负责提取图像特征并对像素位置信息和输入图像特征进行编码;而解码器则包含反卷积层及激活函数,其作用是将处理后的低像素特征有效地转换成高像素的特征,以实现更为精准的像素级分类。

2.2 ME—DeepLabV3+ 模型

DeepLabV3+ 是一种基于 CNN 的语义分割模型,广泛应用于地物识别方面。DeepLabV3+ 能够通过多层卷积、池化和反卷积等操作,有效地抓取样本中的信息。与 FCN、PSPNet、UNet 等模型相比,最大的区别是引入了 ASPP(空洞卷积空间金字塔池化)技术,引入多尺度信息,可以同时处理不同尺度的图像,在不损失像素的前提下,增加接收域的大小,同时保持较高的准确性。

由于 DeepLabV3+ 模型结构比早期的 DeepLab 模型更复杂,需要更多的计算资源和训练时间,因此在训练和部署时需要更多的注意和调整。

2.2.1 替换主干网络

原始的 DeepLabV3+ 采用以 Xception^[22] 为主干的网络。Xception 网络存在结构复杂、参数量过多和计算时间长的缺陷。所以选择轻量级语义分割网络 MobileNetV2^[23, 24] 的改进型 MS—MobileNetV2 来作为新的主干网络。由于 MobileNetV2 拥有较小的参数量和更小的权重模型大小, 大概率能够减少运算时间和内存耗费。MobileNetV2 由深度分离卷积算法、倒残差系统、线性瓶颈机制 3 个模块组成。通过逐像素卷积与逐通道卷积组合形成深度分离卷积, 减少了计算量。倒残差系统通过改变升降维的顺序, 提高了模型的学习能力。在设计线性瓶颈结构时, 选择采用线性激活函数取代传统的 ReLU 函数, 来降低特征信息损失。此外, 通过引入 ReLU6 激活函数替换原有的 ReLU, 进一步提升模型在保持权重信息方面的能力, 提高模型的精度并有效减小量化过程中出现的误差。

由于 UAV 遥感图像具有不同尺度, 高空与低空影像像素、边缘轮廓以及细节都不相同。原始的 MobileNetV2 不能很好地识别多尺度信息, 所以为增强网络对不同拍摄尺度图像的理解能力, 设计 MS—MobileNetV2 网络, 使用多尺度特征集合策略来替换原有结构。在具体实现上, 当卷积操作的步长为 1 时, 保持原有的结构不变; 而在步长为 2 时, 引入多尺度特征融合模块替换原有的瓶颈结构, 以此提升模型的尺度适应性, 如图 3 所示。




图3 MS—MobileNetV2 结构

Fig. 3 Structure of MS—MobileNetV2

2.2.2 加入 ECA 模块

在解码过程中, 集成了高效能的 ECANet 模块。由于无人机获取的 RGB 正射影像由 3 个不同通道组成, 各通道对于特征提取的重要性存在差异。因此, 采用通道注意力机制 (SENet), 使网络能够根据自身需求进行自适应关注。该机制主要包括通道压缩、激发

和重建 3 个步骤, 旨在引导网络专注于关键信息, 进而提高对图像特征的把握能力。

ECA 模块是 SENet 的一个优化变体。SENet 在处理通道注意力时可能会引入不必要的复杂性, 并且在捕捉各个通道间的依赖关系方面效率较低。而 ECANet 通过精简的设计克服了这些问题, 它利用卷积的跨通道信息获取能力, 通过 1D 卷积来学习全局平均池化后的特征。这种方法去除了原始 SE 模块中的全连接层, 简化了模型结构, 同时仍然能够有效地强调每个通道的重要性 (图 4)。因此, ECANet 可以保持较少计算量的同时提升性能, 效率较高。

需要注意: 卷积核的大小很重要, 因为它会改变单个权重计算所考虑的通道数。

1D 卷积核计算如式 (1) 所示。

$$kernel = \text{INT} \left[\text{ABS} \left(\frac{\log_2 channel + 1}{2} \right) \right] \quad (1)$$

$$kernelSize = \text{IF}(\text{MOD}(kernel, 2) = 0, kernel, kernel + 1) \quad (2)$$

式中: $channel$ ——输入的通道数;

$kernel$ ——初始的卷积核大小;

$kernelSize$ ——最终的卷积核大小;

ABS——取绝对值;

INT——转换为整数;

MOD——模数运算函数;

IF——条件判断函数。

通过在网络的解码区 (Decoder) 融入 ECANet, 网络能够自主学习并强化那些地面物体中起决定性作用的通道特征, 给这些特征加权, 不仅提高网络的分类准确度, 还加速次要特征的区分, 进而提升运行效率。




图4 ECA 模块结构

Fig. 4 ECA module structure

2.2.3 修改 ASPP 膨胀率

ASPP 是一种用于多尺度评估的自适应统计池化方法^[27]。通过对图像进行池化操作, 从图像中提取有意义的特征, 并根据这些特征评估图像的质量。原始网络的 ASPP^[6, 12, 18] 采用 3 种不同空洞率的空洞卷积来处理不同像素的遥感图像, 有效捕捉了宽范围的图像特征, 并取得了良好的分类结果。但在高分辨率的无人机低空田间影像处理中, 地物边界更为精细。此时, 只有大卷积核可能会使边界信息捕捉不足, 引起信息损失。为此, 在 ASPP 的自适应样本统计池化模块中引入了空洞

率 $rate$ 为 3 的 3×3 卷积, 形成一种密集的 ASPP 结构, 如图 5 所示。这种新型结构能够更好地适应高像素图像, 并提升模型对精细图像特征的提取能力。




图 5 密集 ASPP 结构

Fig. 5 Dense ASPP structure

通过上述优化, 成功地提高了网络的性能, 减少了训练时间和计算资源消耗, 为实际生产应用提供高效和可靠的解决方案。经过优化的 ME—DeepLabV3+ 网络结构见图 6。




图 6 ME—DeepLabV3+ 模型结构

Fig. 6 ME—DeepLabV3+ model structure

3 试验与结果分析

3.1 试验环境

试验在 Win10 系统环境下进行, 使用 python 3.7, 基于 Pytorch 1.11 平台搭建学习环境, 硬件环境采用 AMD 5600x 处理器, 32 G 内存, GPU 采用 NVIDIA GTX 1080ti。设置 Batch Size 为 12, 意味着每次训练时会使用 12 个数据样本批次。Epoch 设为 100 指的是整个训练集将被用于训练 100 次。初始学习率设为 0.001 是为了给网络一个合理的调整起点。使用 SGD 优化器并在训练过程中调整学习率, 有助于模型更快地收敛到最佳状态。

在数据预处理阶段, 已经采取数据增强措施来解决样本集中不同类别(如玉米、山药、菜地、乔木、大棚、荒地)之间比例失衡的问题, 这对提高模型泛化能力至关重要。此外, 水体、建筑、道路等不同背景可能导致

样本的学习难度不同, 为提高模型对困难图形的分类能力, 将损失函数优化为 Focal Loss。

$$L = -(1 - p_i)^\gamma \log p_i \quad (3)$$

式中: p_i ——二分类概率函数;

L ——损失值;

γ ——动态缩放因子。

该函数通过动态缩放因子 γ 调整标签之间的权重, 令模型更关注难分类的标签, 避免因难度差异而导致的偏差。训练过程中, 当观察到损失值稳定且不再下降时, 认为模型已经收敛或接近收敛, 此时停止训练。

3.2 评价指标

在进行语义分割任务时, 利用混淆矩阵评估模型的性能。评估的度量标准涵盖精确度、召回率、F1 得分、交并比及其平均值。这些度量标准为模型预测结果的精准量化提供了有效手段。精确率 $Precision$ 是预测为正的像素里实际为正的像素所占的比例, 反映了模型预测为正的可靠程度。召回率 $Recall$ 是实际为正的像素里被模型预测为正的像素所占的比例, 反映了模型找出所有实际为正的像素的能力。F1 得分 ($F1-Score$) 整合了精确度和召回率, 提供了一种测量整体性能的方法。交并比 IoU 是分割结果与真实标签的交集、并集的比值, 用于衡量对图像边缘的精度。平均交并比 $mIoU$ 是 IoU 的平均值, 用于衡量对于总体的分割精度。具体计算如式(4)~式(8)所示。

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$$F1-score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (6)$$

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

$$mIoU = \frac{\sum_{i=1}^k IoU_i}{k} \times 100\% \quad (8)$$

式中: TP ——真正例, 预测正确的正样本数量;

FP ——假正例, 预测错误的正样本像素数量;

FN ——假反例, 预测错误的负样本像素数量;

k ——类别总数。

这些指标都是基于混淆矩阵进行计算, 可以用来评估模型的性能和精度。另外, 本文还关注网络的效率和性能, 其参数量越小, 训练用时越少, 则效率越高。

3.3 结果与分析

3.3.1 经典模型对比

为评估 ME—DeepLabV3+ 在图像分类方面的表现, 采用全卷积神经网络 (FCN)、U—Net 以及

PSPNet 等传统深度学习架构作为比较基准,在上述相同条件下进行对比试验。

结合表 1 和图 7 的分割结果来看,FCN 的表现相对较差,在样本 2 和样本 3 中出现了大面积分割错误,总体不如其他模型。出现这种现象的原因是,在 FCN 的编码阶段,通过应用池化层或使用步长大于 1 的卷积层,导致特征映射的尺寸缩小。在玉米、山药、菜地、乔木混杂的情况下,光谱、纹理、几何特征相似,FCN 模型输出图像的分辨率通常比输入图像的分辨率低,难以捕捉其中的细微特征。PSPNet 和 U—Net 的表现优于 FCN。PSPNet 的 $mIoU$ 、精确率、召回率、F1 得分分别

比 FCN 高 2.19%、0.96%、1.63%、1.29%; U—Net 的 $mIoU$ 、精确率、召回率、F1 得分分别比 FCN 高 2.32%、2.02%、0.86%、1.29%。PSPNet 在识别样本 3 和样本 5 中的不规则种植的玉米时出现漏识别,这说明 PSPNet 会将模糊的特征判断为背景。U—Net 在样本 2 中菜地的中心位置出现内涵误差,并且在样本 4 中菜地的识别上有边缘误差,说明 UNet 不善于处理模糊的纹理和边界特征。DeepLabV3+ 的表现略优于上述 3 种模型, $mIoU$ 达到 87.27%,并未出现漏分割和明显的分割错误。这是因为 DeepLabV3+ 引入了 ASPP 技术,在不丢失细节特征的同时达到较高准确性。

表 1 不同模型试验结果对比
Tab. 1 Comparison of experimental results of different models

模型	$mIoU$ /%	精确率/%	召回率/%	F1 得分/%	参数量/M	计算量 FLOPS/G
FCN	84.63	91.79	91.42	91.58	32.95	277.75
PSPNet	86.82	92.75	93.05	92.87	46.71	118.43
U—Net	86.95	93.81	92.28	92.87	24.89	451.84
DeepLabV3+	87.27	92.94	93.33	93.10	54.71	166.88
ME—DeepLabV3+	90.97	95.04	95.41	95.22	6.67	54.77




图 7 不同模型分割效果对比

Fig. 7 Comparison of segmentation effects of different models

ME—DeepLabV3+ 模型在 $mIoU$ 及精确率上较 DeepLabV3+ 有较大提高,明显优于 FCN、PSPNet 和 U—Net 模型,并且参数量及计算量大幅减少。这是因为 ME—DeepLabV3+ 在 DeepLabV3+ 的基础上替换了 MS—MobileNetV2 主干网络,增加空洞卷积膨胀率,加入了高效通道注意力网络模块,实现高低维特征融合,增强了模型捕获上下文信息的能力。由图 8 可知,第 1 次训练之后损失值最小的是 ME—DeepLabV3+ 模型,并且其收敛速度也超过其他模型,在第 20 次训练时接近收敛且损失值低于对比模型。




图 8 不同模型损失值

Fig. 8 Loss value of different models

3.3.2 模型改进前后对比

为进一步验证 ME—DeepLabV3+ 的优越性,主要进行 ME—DeepLabV3+ 与原始模型比较与分析。

1) 整体性能对比。由表 2 可知,ME—DeepLabV3+ 模型相比于原模型在所有评价指标上都实现显著提高。具体来说,召回率增加 2.08%,精确率提升 2.1%,F1 得分提高 2.12%, $mIoU$ 提升 3.7%。此外,与原始的 DeepLabV3+ 模型相比,改进后的模型参数量由 54.71 M 大幅减少至 6.67 M,仅占原模型的 12.2%,同时训练时间从 8.5 h 缩短到 4.2 h,减少 50.5%。这些改进归功于主干网络 MS—MobileNetV2 使用的深度可分离卷积模块和高低维特征融合策略,它们不仅大幅降低了网络的计算复杂度,还通过加入 ECA 模块,加快了对关键特征的检测速度。高低维特征融合策略有效地补偿了高层特征提取过程中可能出现的边界信息损失问题,在大幅减少参数量和计算消耗的同时,提升了对玉米、山药、菜地、乔木、大棚、荒地边界轮廓的分割效果。

表 2 模型改进前后对比
Tab. 2 Comparison before and after model improvement

模型	<i>mIoU</i> /%	精确率/%	召回率/%	<i>F1</i> 得分/%	参数量/M	训练用时/h
DeepLabV3+	87.27	92.94	93.33	93.10	54.71	8.5
ME—DeepLabV3+	90.97	95.04	95.41	95.22	6.67	4.2

2) 精确率和交并比对比。由表 3 可知,原始 DeepLabV3+对玉米、山药、荒地、乔木、菜地、大棚的分类精度分别为 96.15%、96.57%、90.61%、89.63%、90.60%、94.10%。而改进后的模型在玉米、山药、荒地、乔木、菜地、大棚的分类精度上分别达到 96.85%、97.72%、95.65%、92.22%、91.55%、96.28%,较原模型分别提高 0.7%、1.15%、5.04%、2.59%、0.95%、2.18%。其中,荒地的分类精度提升最为显著。考虑在正射影像中,荒废地块与种植蔬菜地块在光谱、纹理特征上相似,原始模型的 ASPP 获取的荒废地块细致特征不足。而改进后的模型中增加了更细微的空洞率,并且替换的主干网络中加入高低维特征融合从而提升了对

地块边缘特征的捕捉效果。相比之下,玉米的分类精度提升较为有限,可能是因为玉米在颜色、纹理和形状上的特征相对较为单一。经过模型优化,玉米、山药、荒地、乔木、菜地和大棚的平均召回率及平均 *F1* 得分分别提升 2.08%、2.12%,改进后的模型在提高田间作物和其他地理要素的分类准确性方面具有显著效果。使用交并比(*IoU*)指标来评估所提出的农村田间分类方法在目标检测的形状和轮廓方面的性能。根据表 3 的数据,改进后的模型在玉米、山药、菜地、乔木、大棚和荒地类别的 *IoU* 均有明显提升,玉米和山药的 *IoU* 增幅相对较小。这表明 *IoU* 作为评价指标,在反映分类结果的形状和面积方面比基于像素的精度评价更为合适。

表 3 模型改进前后精确率对比
Tab. 3 Comparison of accuracy before and after model improvement

模型	精确率/%						<i>IoU</i> /%					
	玉米	山药	荒地	乔木	菜地	大棚	玉米	山药	荒地	乔木	菜地	大棚
DeepLabV3+	96.15	96.57	90.61	89.63	90.60	94.10	94.89	93.00	86.33	84.58	77.00	87.80
ME—DeepLabV3+	96.85	97.72	95.65	92.22	91.55	96.28	95.874	94.26	91.16	88.19	83.54	92.77

3) 样本分割效果对比。选取 4 个植被覆盖比例各异的样本进行深入分析,如图 9 所示。




图 9 模型改进前后分割效果对比
Fig. 9 Comparison of segmentation effects before and after model improvement

由图 9 可以看出,样本 1 中玉米和菜地相交错,样本 2 中树木覆盖度高,样本 3 中有荒地,而样本 4 中山

药、玉米、菜地混合。对比前后的结果,可以观察到改进网络对玉米、山药、菜地、乔木、大棚和荒地的分类效果均优于原始模型。情况如下:玉米、菜地的交错分布区域,原始模型部分像素识别错误,存在过分割,条状种植的玉米被错误地识别为山药,改进模型的分割效果整体上更为准确;当树木比较稀疏时,原始模型分割会将更多的背景识别为树木,而改进模型能更精准地识别出树木的边界;在山药、玉米、菜地混合时,改进模型能够清晰地分割出它们之间的边界。总体而言,优化后模型的识别结果有了显著改善。

3.3.3 消融实验

模型改进对比试验说明 ME—DeepLabV3+模型在田间地块地物分类数据集上具有更好的分割效果。为进一步验证上述改进点对 DeepLabV3+提升的有效性,对相关模型做消融实验,精确率和交并比评估结果如表 4 所示。其中 DP1 代表替换主干网络为 MS—MobileNetV2;DP2 和 DP3 代表在原模型中加入高效通道注意力机制和修改 ASPP 膨胀率;DP4 代表同时替换主干网络和加入 ECA 模块。

由表 4 可知,替换主干网络为 MS—MobileNetV2 的 DP1 相对于原网络有了一定的提升,精确率提高 1.93%,*mIoU* 提高 2.19%,并且缩短 56%的训练用

时,说明替换主干网络对田间地物识别的精度提高是有效的,且运行效率提高非常显著。相比于 DeepLabV3+,DP2 和 DP3 的精确率略微提升,DP3 的 $mIoU$ 提升 2.07%,说明调整 ASPP 空洞率对

地物不同尺度大小及不同形状 的识别率提升有效。综上所述,提出的 ME—DeepLabV3+模型相比于原模型提高了识别精度和训练效率,减少了参数量,并且大幅降低训练用时。

表 4 消融实验结果对比
Tab. 4 Comparison of ablation experiment results

模型	M2	ECA	AS3	精确率/%	$mIoU$ /%	训练用时/h
DeepLabV3+	×	×	×	92.94	87.27	8.5
DP1	✓	×	×	94.87	89.46	3.7
DP2	×	✓	×	93.82	88.04	8.9
DP3	×	×	✓	93.81	89.34	9.1
DP4	✓	✓	×	94.94	90.33	3.9
ME—DeepLabV3+	✓	✓	✓	95.04	90.97	4.2

4 结论

针对农村田间地块地物分类问题,采集蠡县田间种植区的低空无人机 RGB 影像,充分利用色彩、纹理信息构建数据集,训练多种深度学习模型进行试验。

1) 选择其中相对较优模型 DeepLabV3+,在其基础上进行 3 个方面改进(替换主干网络、添加通道注意力、调整 ASPP 膨胀率),提出 ME—DeepLabV3+模型。

2) 试验结果表明,所用的 5 种原始深度学习模型均可用于研究土地利用识别。所提出的 ME—DeepLabV3+模型在验证集上的语义分割性能表现优异,具体表现在 $mIoU$ 、精确率、 $F1$ 得分和召回率分别为 90.97%、95.04%、95.22%和 95.41%,较原始模型分别提高 3.7%、2.1%、2.12%、2.08%。在玉米、山药、荒地、乔木、菜地、大棚的分类精度上分别提高 0.7%、1.15%、5.04%、2.59%、0.95%、2.18%。改进模型的参数量减少 87.8%,训练用时减少 50.5%。

深度学习模型能够较好地实现田间土地利用的准确分类。受试验条件限制,本研究的样本基于一个试验区且来自同一时间段。考虑到不同季节植被的影像信息差异,后续试验可以关注不同地区、不同时间的更多识别种类的多时相样本,提升模型的适用性及准确度。

参 考 文 献

[1] 李亮,沈诗逸,周磊,等.海南自贸港发展空间需求下的农村土地改革研究[J].中国农机化学报,2023,44(12):217—222,254.
Li Liang, Shen Shiyi, Zhou Lei, et al. Research on rural land reform under the development space demand of Hainan free trade port [J]. Journal of Chinese Agricultural Mechanization, 2023, 44(12): 217—222,254.

[2] 郝雪纯,王志强,李莉,等.西部地区“水—能源—粮食”系统

安全评价及障碍因子识别研究[J].中国农机化学报,2023,44(11):250—257.

Hao Xuechun, Wang Zhiqiang, Li Li, et al. Study on security evaluation and obstacle factor identification of “Water-Energy-Food” system in Western China [J]. Journal of Chinese Agricultural Mechanization, 2023, 44(11): 250—257.

[3] Li Z, Chen G, Zhang T. A CNN-transformer hybrid approach for crop classification using multitemporal multisensor images [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 847—858.

[4] Gudmann A, Csikós N, Szilassi P, et al. Improvement in satellite image-based land cover classification with landscape metrics [J]. Remote Sensing, 2020, 12(21): 3580.

[5] 赵胜利,王国宾,胡连槟,等.基于无人机多光谱遥感的棉花生长参数和产量估算[J].中国农机化学报,2024,45(2): 227—234.
Zhao Shengli, Wang Guobin, Hu Lianbin, et al. Estimation of cotton growth parameters and yield based on UAV multi-spectral remote sensing [J]. Journal of Chinese Agricultural Mechanization, 2024, 45(2): 227—234.

[6] Kang Y, Hu X, Meng Q, et al. Land cover and crop classification based on red edge indices features of GF—6 WFV time series data [J]. Remote Sensing, 2021, 13(22):4522.

[7] Chew R, Rineer J, Beach R, et al. Deep neural networks and transfer learning for food crop identification in UAV images [J]. Drones, 2020, 4(1): 7.

[8] Yang Q, Shi L, Han J, et al. A near real-time deep learning approach for detecting rice phenology based on UAV images [J]. Agricultural and Forest Meteorology, 2020, 287: 107938.

[9] Bah M D, Hafiane A, Canals R. CRowNet: Deep network for crop row detection in UAV images [J]. IEEE Access, 2019, 8: 5189—5200.

[10] Kitano B T, Mendes C C T, Geus A R, et al. Corn

- plant counting using deep learning and UAV images [J]. IEEE Geoscience and Remote Sensing Letters, 2019.
- [11] Huang H, Lan Y, Yang A, et al. Deep learning versus object-based image analysis (OBIA) in weed mapping of UAV imagery [J]. International Journal of Remote Sensing, 2020, 41(9): 3446–3479.
- [12] Chen L C, Papandreou G, Kokkinos I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs [J]. arXiv preprint arXiv: 1412.7062, 2014.
- [13] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834–848.
- [14] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation [J]. arXiv preprint arXiv:1706.05587, 2017.
- [15] Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801–818.
- [16] 郭金, 宋廷强, 孙媛媛, 等. 改进 DeepLabV3+ 的双注意力融合作物分类方法 [J]. 计算机工程与应用, 2024, 60(8): 110–120.
- [17] 张志博, 赵西宁, 姜海晨, 等. 基于无人机影像和深度学习的渭北旱塬区土地利用精准分类 [J]. 农业工程学报, 2022, 38(22): 199–209.
- [18] 张泉, 冯莉, 朱榴骏, 等. 基于无人机正射影像的城市居民区植被分类 DeepLabV3+ 模型改进实验 [J]. 地理与地理信息科学, 2023, 39(3): 40–47.
- [19] Wang Y, Fu T, Chen X, et al. Self-supervised local rotation-stable descriptors for 3D ultrasound registration using translation equivariant FCN [J]. Pattern Recognition, 2024: 110324.
- [20] Yu J, Cheng T, Cai N, et al. Wheat lodging segmentation based on LSTM_PSPNet deep learning network [J]. Drones, 2023, 7(2): 143.
- [21] Chen Z, Luo F, Li R, et al. Modeling the flow and geomorphic heterogeneity induced by salt marsh vegetation patches based on convolutional neural network UNet-Flow [J]. Journal of Geophysical Research: Earth Surface, 2024, 129(2): e2023JF007336.
- [22] Saedi S I, Rezaei M. A modified Xception deep learning model for automatic sorting of olives based on ripening stages [J]. Inventions, 2023, 9(1): 6.
- [23] Sandler M, Howard A, Zhu M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510–4520.
- [24] Liu Y, Miao C, Ji J, et al. MMF: A multi-scale MobileNet based fusion method for infrared and visible image [J]. Infrared Physics & Technology, 2021, 119: 103894.

(上接第 351 页)

- [5] 费威, 佟烁. 消费者视角下网售进口食品安全监管满意度影响因素分析 [J]. 软科学, 2019, 33(7): 122–128.
Fei Wei, Tong Shuo. Study on influencing factors of imported food safety supervision satisfaction in online sales from the perspective of consumers [J]. Soft Science, 2019, 33(7): 122–128.
- [6] 赵丙艳. 移动电子商务背景下消费者感知价值对行为意向的影响 [J]. 当代经济管理, 2020, 42(3): 34–38.
Zhao Bingyan. Research on the influence of consumer perceived value on consumer behavior intention in mobile e-commerce situation [J]. Contemporary Economic Management, 2020, 42(3): 34–38.
- [7] 杜义日格其, 乌云花. 消费者的信任、质量安全认知及乳制品购买行为的研究进展 [J]. 中国乳品工业, 2019, 47(3): 47–51.
- [8] 涂洪波, 胥草森, 赵晓飞. O2O 生鲜电商平台消费者重购意愿影响机制 [J]. 中国流通经济, 2021, 35(4): 38–47.
Tu Hongbo, Xu Caosen, Zhao Xiaofei. Research on the influence mechanism of consumers' repeated purchase intention on O2O fresh e-commerce platform [J]. China Business and Market, 2021, 35(4): 38–47.
- [9] 李波, 张春燕, 张俊飏. 食品企业质量安全意识提升的演化博弈逻辑——基于乳制品行业消费者重复购买行为 [J]. 中国管理科学, 2024, 32(4): 315–324.
Li Bo, Zhang Chunyan, Zhang Junbiao. The evolutionary game logic of the improvement of quality and safety awareness of food enterprises: Based on the repeated purchase behavior of consumers in the dairy industry [J]. Chinese Journal of Management Science, 2024, 32(4): 315–324.
- [10] 刘禹彤, 崔鑫妍, 周德. 消费者对禽类食品安全风险感知及其影响因素 [J]. 黑龙江农业科学, 2018(11): 116–121.
Liu Yutong, Cui Xinyan, Zhou De. Consumers' perception of poultry food safety risk and its influencing factors [J]. Heilongjiang Agricultural Sciences, 2018(11): 116–121.
- [11] 唐赫, 许博洋. 消费者食品安全治理意愿的实证归因: 基于计划行为理论的链式中介与调节模型 [J]. 中国食品卫生杂志, 2022, 34(6): 1275–1281.
- [12] 王建华, 陶君颖, 陈璐. 消费者安全食品购买意愿与支付行为: 偏差识别与影响因素 [J]. 江海学刊, 2019(3): 86–93, 254.
Wang Jianhua, Tao Junying, Chen Lu. Consumers' purchase intention and payment behavior for safe food: Deviation identification and influencing factors [J]. Jianghai Academic Journal, 2019(3): 86–93, 254.