doi:10.6041/j.issn.1000-1298.2025.02.015

基于改进 U－Net 的高分辨率正射影像图田间可行驶道路提取方法

金智文　王　宁　肖坚星　王天海　仇瑞承　李　寒　张　漫
（中国农业大学智慧农业系统集成研究教育部重点实验室，北京 100083）

摘要：田间可行驶道路边界信息获取是制作农田高精度地图的基础。针对现有方法对高分辨率正射影像图中田间可行驶道路分割不准确、出现漏检误检等问题，本文提出了一种基于改进 U－Net 的深度学习网络模型。该方法首先将主干网络更换为 ResNet50，增强对田间可行驶道路特征提取能力；其次，融合可以提高管状结构精度的 DSConv 模块提高对田间可行驶道路的精度，并抑制与田间道路类似的田间地物背景的特征提取；最后，通过插入 ECA－Net 注意力机制来获取完整的上下文信息，优化田间可行驶道路的特征还原过程，从而达到提高模型整体分割精度的目的。在此基础上，通过传统图像处理方法对分割结果进一步地去噪、消孔，从而获取高精度的田间可行驶道路边界信息。试验结果表明，改进 U－Net 模型在所构建数据集的测试集上 MIoU、MPA 分别达 91.12%、95.46%，与其他对比模型相比具有最高的评价指标值，使用传统图像处理方法后处理后，MIoU 和 MPA 为 92.64% 和 96.75%，分别提高 1.52、1.29 个百分点；在对高分辨率正射影像图田间可行驶道路的识别测试中，MIoU 和 MPA 分别达 86.39% 和 90.01%，可以明显地识别田间可行驶道路；使用传统图像处理方法后对获得的高分辨率正射影像图结果进行优化后，MIoU 和 MPA 分别为 88.34%、91.53%，分别提高 1.95、1.52 个百分点。该研究可以为后续制作农田高精度地图提供准确的田间可行驶道路边界信息。

关键词：田间道路提取；语义分割；无人机；正射影像图；深度学习
中图分类号：TP75　　**文献标识码**：A　　**文章编号**：1000-1298(2025)02-0155-09　　**OSID**：

Field Road Extraction Method Based on Improved U－Net for High-resolution Orthophoto Maps

JIN Zhiwen　WANG Ning　XIAO Jianxing　WANG Tianhai　QIU Ruicheng　LI Han　ZHANG Man
(*Key Laboratory of Smart Agriculture System Integration Research*, *Ministry of Education*, *China Agricultural University*, *Beijing* 100083, *China*)

Abstract: The acquisition of field road boundary information is the basis for making high-precision farmland map. In order to solve the problems of inaccurate segmentation of field roads in high-resolution orthophoto maps, such as missed segmentation and false segmentation, a deep learning network model was proposed based on improved U－Net. Firstly, the backbone network was replaced with ResNet50 to enhance the ability to extract the features of drivable roads in the field. Secondly, the DSConv module, which can improve the accuracy of tubular structure, improved the accuracy of the field drivable road, and inhibited the feature extraction of the background of field features similar to the field road. Finally, the complete context information was obtained by inserting the ECA－Net attention mechanism, and the feature restoration process of the drivable road in the field was optimized, so as to improve the overall segmentation accuracy of the model. Then the traditional image processing method was used to further denoise and eliminate the hole of the segmentation results, and in view of the problem of losing geographic information in the recognition results, so as to obtain high-precision field road boundary information. The experimental results showed that the improved U－Net model had the highest evaluation index values in the comparison with the semantic segmentation model in the test set of the constructed

收稿日期：2024－11－26　修回日期：2024－12－28
基金项目：国家重点研发计划项目(2021YFD200060402)和中国农业大学 2115 人才工程项目
作者简介：金智文(1999—)，男，硕士生，主要从事农田高精度地图构建方法研究，E-mail：s20223081663@cau.edu.cn
通信作者：张漫(1975—)，女，教授，博士生导师，主要从事智慧农业及其支持技术研究，E-mail：cauzm@cau.edu.cn

dataset with 95.46% MPA and 91.12% MIoU, after post-processing using traditional image processing methods, MIoU and MPA were 92.64% and 96.75%, respectively, the MIoU and MPA were increased by 1.29 percentage points and 1.52 percentage points; and 86.39% and 90.01% in the field drivable road recognition test of high-resolution orthophoto map, respectively, which can clearly identify the field road. After using the traditional image processing method to optimize the obtained high-resolution orthophoto results, the MIoU and MPA were 88.34% and 91.53%, respectively, and the MIoU and MPA were increased by 1.95 percentage points and 1.52 percentage points, respectively. The research result can provide accurate field road boundary information for the subsequent production of high-precision farmland map.

Key words: field road extraction; semantic segmentation; UAV; orthophoto maps; deep learning

0 引言

农业机械自主无人导航技术是实施智慧农业的关键技术之一[1],被广泛应用于农作物的耕种、播种、收获和施肥等任务,缓解了劳动力不足和生产效率低等问题。工作中的农机大多需要在机库与农田、农田与农田等场景下频繁行驶转移,此时田间可行驶道路边界的信息尤为重要。现有研究主要依靠学者手工采集田间可行驶道路数据[2],存在工作效率低、耗时长、重复性工作量大等问题。随着激光雷达、深度相机等车载设备的发展,获取田间道路边界信息的技术与算法不断涌现[3-4],但仍难以应用到一些特征均一化的复杂农田场景[5]。由于田间可行驶道路的边界并不明显,周边常有泥土和杂草,使得道路边界更加模糊,给田间道路边界提取带来了更大挑战。

随着遥感技术快速发展,基于遥感图像的语义分割为农田道路边界的快速、精准、低成本获取提供了可能。遥感图像通常分为卫星遥感图像和无人机遥感图像。卫星遥感图像由于像幅面积大、宏观性强,导致图像分辨率有限、无法提供高精度的地表信息;而当前快速发展的无人机遥感被应用于农业各个场景中[6-8],其分辨率可达厘米级[9-11],可准确获取区域边界。为田间道路边界信息的准确获取提供了可能。然而由于原始无人机遥感图像中的噪声、遮挡以及背景的复杂性[12-14],从高分辨率农田遥感图像中提取道路仍存在挑战。

近年来,深度学习与无人机遥感技术的结合取得了很好的效果[15-17]。与传统方法相比,这些深度学习方法的结果更好,分割精度更高,证明了深度学习技术与无人机遥感结合的巨大潜力。道路提取通过对各类场景下的道路图像进行语义分割,语义分割是像素级的分类任务,即对每一个像素进行背景和道路的二分类任务,从而提取可行驶道路区域[18-21]。尽管现有方法以无人机图像为基础进行语义分割,在农业背景下提取的田间可行驶道路信息方面取得了一定的进展,但仍存在精度不高、边界模糊等问题。

针对上述问题,提出一种改进的端到端神经网络,结合传统图像处理方法进行后处理,解决分割过程中所产生的少量噪声及道路断裂空洞问题,对无人机正射影像图进行田间道路提取,从而获取高精度田间道路边界信息,以期为农田高精度地图制作提供基础。

1 材料与方法

1.1 数据集构建与预处理

1.1.1 数据获取

(1) 无人机图像数据集获取

2023 年 3 月在河北省涿州市中国农业大学涿州实验站采用无人机进行数据采集,时间为10:00—12:00,天气晴朗,日光充足,保证了航拍质量。所使用图像采集设备为大疆 Mavic 3M 型无人机,其配备了 RGB 相机和 GPS 接收机。具体参数设置如表 1 所示,摄像机与地面垂直90°,获得无人机图像 1 012 幅;对采集后的图像进行筛选,去除没有出现田间道路或者模糊的图像数据,获得图像 963 幅,如图 1a、1b 所示。为了丰富数据集的多样性从而增强模型的泛化能力,通过网上搜索开源遥感数据集并筛选,获得图像 400 幅,如图 1c 所示,尺寸均为 256 像素 × 256 像素;最终获得无人机遥感图像 1 363 幅。

表 1 无人机参数

Tab.1 Parameters of UAV

参数	数值
摄像头有效像素	2×10^7
曝光时间/s	0.001
最长飞行时间/min	46
图像分辨率/(像素 × 像素)	4 000 × 3 000
飞行高度/m	20
重叠率(横向和纵向)/%	70

(2) 高分辨率正射影像图获取

由于制作农田高精度地图的底图一般为高分辨


(a)　(b)　(c)

图 1　数据集图像

Fig. 1　Dataset image

率正射影像图，实现对高分辨率正射影像图的提取非常重要。为实现对高分辨率正射影像图的田间可行驶道路提取，需要获取一定数量的高分辨率正射影像图进行相应测试。数据分别采集于上海市青浦区联适生态无人化农场青浦基地与中国农业大学涿州实验站。前者农田环境复杂，地块和道路周边种有树木，采集时间集中在 10:00—14:00，此时间段内光照强烈，树木导致的阴影对田间可行驶道路的边界有所影响；此外，该区域部分地段周围分布着不同的建筑物、池塘及树林，这些因素在一定程度上对道路造成遮挡。其次，该区域结构化与非结构化道路交错，且多数地块为主要种植水稻的水田，地块之间存在一定的高度差。相比之下，后者位于平原地带，地块以旱地为主，包含部分荒地，荒地与道路周围长满杂草。地块上的主要种植作物为玉米，数据采集时正值玉米发芽期，地块和道路附近有建筑物及温室，伴随有少量树木。数据采集时间为 09:00—10:00，光照强度适中。综上所述，两地农田环境各具特色，这种多样性为验证所提方法的鲁棒性和有效性提供了良好数据基础。两地分多个区域进行航飞采集，图像采集设备为大疆 Mavic 3M 型无人机，设定重叠率为 75% 以保证后续的拼接，将采集的无人机图像数据使用 Pix4d mapper 等软件进行拼接，获取原始的高分辨率正射影像图，最终获得 28 幅，如图 2 所示，获取的高分辨率正射影像图的地面采样间隔（GSD）为 3.5 ~ 5.0 cm/像素，满足高精度要求。



图 2　原始高分辨率正射影像图

Fig. 2　Original high-resolution orthophoto map

1.1.2　数据预处理

根据试验要求构建田间道路数据集，首先使用开源标注工具 Labelme，按照 Pascal VOC2007 的数据集格式对无人机遥感图像进行标注，获取标准的语义分割数据集，并确保每幅图像都有相应的标签文件，田间道路标签设定为“road”。其次，对标注好的数据集按比例 9:1随机划分为训练集、测试集，训练集、测试集分别为 1 223、140 幅。最后，对训练集通过镜像和随机旋转 0° ~ 45°数据增强方式将训练集图像数量由原来的 1 223 幅扩增为 3 669 幅，并将扩增后的训练集按比例 9:1随机划分为子训练集和验证集，扩增后图像对比如图 3 所示。

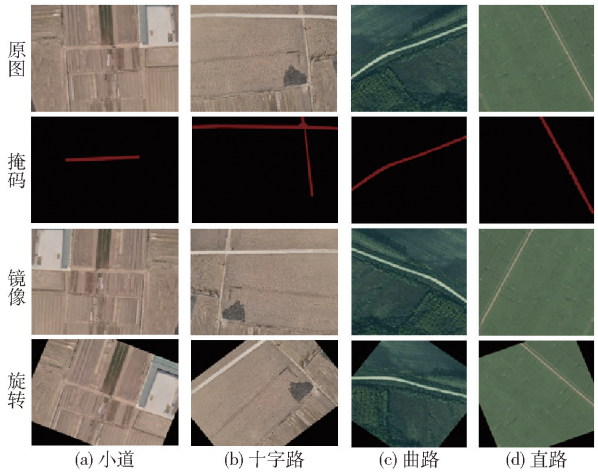

图 3　扩增后图像对比

Fig. 3　Comparison of images after augmentation

通过拼接所获得的原始高分辨率正射影像图需要进行处理，保证后续测试的正常进行，处理流程如图 4 所示。首先基于 GIS 处理软件对高分辨率正射影像图进行裁剪，去除不相关和拼接所产生的畸变变形等区域，对裁剪后的高分辨率正射影像图进行标注处理，标注出对应的田间可行驶道路区域，并导出该高分辨率正射影像图的掩码作为后续测试所用真值。

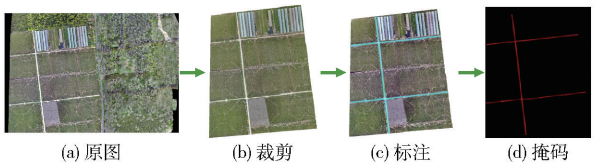
(a) 原图　(b) 裁剪　(c) 标注　(d) 掩码

图 4　高分辨率正射影像图处理过程

Fig. 4　High-resolution orthophoto map processing process

1.2　网络模型改进

1.2.1　U－Net 模型改进

U－Net[22] 是一个基于卷积神经网络的端到端图像分割模型，由编码器和解码器 2 部分组成，编码器用来进行特征信息的提取，而解码器则将获得的特征图像进行重建并生成分割后的图像。U－Net 通过跳跃连接解码部分上采样后的特征图与编码部分对应层的特征图进行拼接融合，实现了图像深层

语义信息和浅层空间信息的结合,可以提高模型准确性,在一定程度上解决了梯度消失的问题,并且有助于提高分割结果的精细程度。

改进 U－Net 网络保留了与原 U－Net 相同的编码器-解码器结构和跳跃连接,结构如图 5 所示。原 U－Net 网络采用卷积和池化操作来进行特征提取,利用跳跃连接和上采样进行田间可行驶道路特征还原。改进 U－Net 网络采用 ResNet50[23] 作为主干网络,以显著提高模型编码器的田间可行驶道路特征提取能力,有效提升对田间可行驶道路的特征提取整体精度。同时在编码器和解码器的连接处引入动态蛇形卷积模块[24],以进一步提高对田间道路类型管状特征的提取精度,并抑制与田间道路类似的田间地物背景的特征提取,从而提高田间可行驶道路整体的分割精度。此外,在编码器中加入注意力机制 ECA－Net[25],在不提高模型参数量和计算量的前提下,实现对特征提取过程中所获全局信息的有效融合,从而优化田间可行驶道路的特征还原过程,减少农田环境干扰,进一步提高模型整体分割精度。

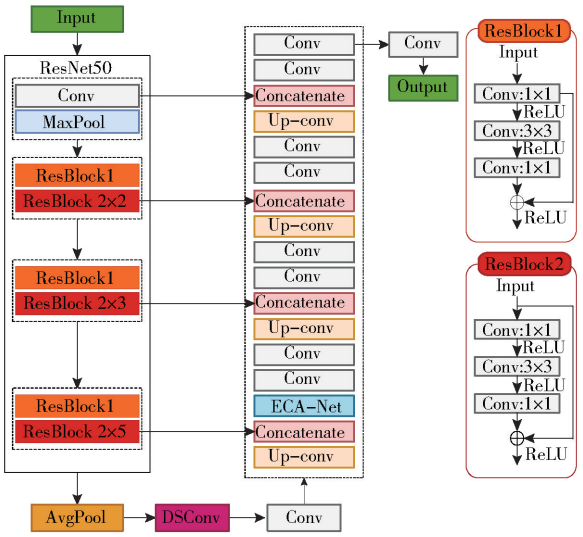

图 5 改进 U－Net 模型结构

Fig. 5 Improved U－Net model structure

1.2.2 主干网络优化

由于农田环境复杂,田间可行驶道路占比少、不规则,杂草植被使得边界模糊,原 U－Net 的主干网络特征提取能力在农田场景下的应用效果并不好,出现误检和漏检较多,无法实现对田间可行驶道路的准确识别。为解决这一问题,将 U－Net 原主干网络更换为 ResNet50,ResNet50 有 50 层,包括卷积层、池化层和全连接层,其中穿插着残差连接。ResNet50 在其残差块中使用瓶颈架构来保持效率,这种架构减少了参数量和计算负载。ResNet50 的残差连接方便模型的训练,有助于缓解训练过程中梯度消失问题。在复杂的农田环境中 ResNet50 可通过它的深层架构提取田间可行驶道路的深层复杂特征,从而将田间可行驶道路与周围的田地、植被的背景元素分割出来,这种提取特征的能力可以有效地将田间狭窄或不规则道路准确提取出来。

1.2.3 蛇形卷积模块

管状结构道路特点是细长且边界不明显,无人机所拍摄图像中所包含的田间道路结构只占整体图像的一小部分,标准卷积、空洞卷积无法聚焦目标特征而调整关注区域,可变形卷积可以自适应地学习感兴趣区域,但对于管状目标结构,可变形卷积无法限制关注区域的连通性,而 DSConv 可以限制,使得其更适合管状场景。DSConv 通过自适应地关注细长且边界模糊的田间道路,来精确地捕捉田间道路特征。

在农田场景中,可行驶道路中非结构化道路多为田间小道,无明显清晰的道路边界,为应对非结构化道路无清晰边界的问题,本研究在模型编码器和解码器之间引入 DSConv,有效解决非结构化道路边界识别难题,提高了非结构化道路信息的提取精度,减小农田环境对结果的干扰。在主干网络进行特征提取后,所获得的特征图通过 DSConv 可有效减少背景噪声,降低误检率。田间可行驶道路通常具有复杂且不规则的边界形态,DSConv 能够灵活地适应边界变化,更好地捕捉到农田环境下可行驶道路的特征细节。

1.2.4 注意力机制

ECA－Net 是轻量化的注意力机制模块且有着更高的计算效率,能够增强神经网络对图像特征的建模能力。ECA－Net 通过简单有效的通道注意力机制,自动学习通道之间的相关性,突出田间可行驶道路特征,减少农田环境干扰,从而在提取田间可行驶道路时更加准确,减少漏检和误检;ECA－Net 引入了一种不需要显示卷积操作的通道间作用方式,减少参数的同时捕获通道间的依赖关系,提升模型表达能力。

ECA－Net 结构图主要包括全局平均池化(Global average pooling,GAP)层和一维卷积层,如图 6 所示,其大致结构如下:

(1)全局平均池化(GAP)层:用于对输入特征图的每个通道进行平均池化,得到 1 个一维的特征向量,其长度与通道数相同。有助于捕获全局上下文信息,并减小模型计算复杂度。

(2)一维卷积层:用于学习不同通道之间的相关性,并生成通道权重。其卷积核大小是自适应的,通过一个函数来确定,使得在通道数较大的层可以

更多地进行跨通道交互。这种设计既减少了模型参数量，又增强了模型性能。

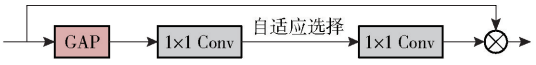

图 6　ECA－Net 结构

Fig. 6　ECA－Net structure

1.3　模型训练与评价指标

1.3.1　模型训练

在处理器为 Intel(R) Core(TM) i5－12490F、内存为 32 GB、GPU 为 NVIDIA Geforce RTX4060ti GPU、显存为 8 GB、操作系统为 Windows 的计算机上进行。并行计算框架为 CUDA 12.2。所有程序均基于 Python 3.8，深度学习框架采用 Pytorch 框架以及 CUDA 12.2。

相关参数设置：epoch 为 100，batch size 为 4，采用不冻结网络的训练方式，初始学习率为 1×10^{-4}，最小学习率为 1×10^{-6}。输入尺寸为 512 像素×512 像素，所有图像输入前均进行 resize 处理，使其尺寸保持为 512 像素×512 像素，将 Cosine annealing (Cos)[26] 设置为本试验中的学习率调整策略，以确保网络的良好收敛性，同时防止过拟合。为适应学习变化的速率，采用 Adam[27]，并将动量(momentum)设置为 0.9，选择 Dice_Loss 作为损失函数，用来处理前景和背景类别不平衡问题，即

$$Dice_{Loss}=1-\frac{2\sum_{i=1}^{N}p_i g_i}{\sum_{i=1}^{N}p_i^2+\sum_{i=1}^{N}g_i^2}$$

式中　N——像素总数

p_i——网络预测的第 i 个像素值

g_i——真实标签中第 i 个像素值

1.3.2　模型评价指标

为了比较分割模型实际结果和性能，采用 MIoU、MPA 两个重要指标对模型分割精度进行评估。MIoU 是语义分割模型常用的准确率度量标准，反映预测结果与图像真实结果的重合程度。MPA 是衡量分割任务中每个类准确性的指标。PA 为正确预测像素数量和图像像素总量的比值，通过对所有类别的 PA 求平均值来计算 MPA。同时，使用单幅测试集图像平均推理速度和模型参数量来衡量网络复杂程度。

1.4　后处理

基于改进 U－Net 分割模型获得田间可行驶道路分割结果后，需要使用传统图像处理方法对分割结果进行优化。由于复杂的农田环境，导致分割结果出现部分细微噪声以及空洞现象，这些误分割区域及未检测到的区域会影响田间可行驶道路分割结果。优化高分辨图像分割结果后续处理步骤：将获取的图像进行二值化操作，获得对应的二值化图像，便于进行图像处理，对二值化图像进行相应的图像形态学处理，获得最终优化后的结果。

2　结果与讨论

2.1　消融试验

为了探究改进 U－Net 中各模块对分割精度的影响，验证各模块的有效性，开展消融试验。在试验环境和超参数保持相同的条件下，探索不同主干网络和不同注意力机制模块对模型效果的影响。基准网络为 U－Net，更换不同的主干网络如 MobileNetV2[28]、ResNet50 和 Ghost_ResNet50[29]，同时在更换主干网络为 ResNet50 的基础上，融入 DSConv 模块及注意力机制 ECA－Net 后在测试集上进行测试，MIoU、MPA 及对应模型参数量如表 2 所示。

表 2　消融试验结果对比

Tab. 2　Comparison of ablation experiments

模型	MPA/%	MIoU/%	参数量
U－Net	89.40	85.16	$1.885\,4\times10^7$
U－Net－MoblieNetV2	53.17	49.67	$8.385\,0\times10^6$
U－Net－Ghost_ResNet	52.94	49.63	$2.642\,7\times10^7$
U－Net－ResNet50	94.87	90.85	$4.393\,3\times10^7$
U－Net－ResNet50－DSConv	95.01	90.87	$5.662\,8\times10^7$
U－Net－ResNet50－DSConv－ECA－Net	95.46	91.12	$5.663\,2\times10^7$

由表 2 可知，U－Net－MobileNetV2 模型参数量最低，模型较轻量，但其分割精度不高，MPA 和 MIoU 分别为 53.17%、49.67%。U－Net－Ghost_ResNet 模型参数量为 $2.642\,7\times10^7$，MPA 和 MIoU 为 52.94% 和 49.63%，两者相较于原 U－Net 的精度下降，而 U－Net－ResNet50 模型 MPA 和 MIoU 分别为 94.87%、90.85%，相较于原 U－Net 分别提高 5.47、5.69 个百分点；U－Net－ResNet50－DSConv 模型 MPA 和 MIoU 分别提高 0.14、0.02 个百分点，参数量达到 $5.662\,8\times10^7$，而 U－Net－ResNet50－DSConv－ECA－Net 相应的 MPA 和 MIoU 分别提高 0.45、0.25 个百分点，参数量达到 $5.663\,2\times10^7$。结果表明，主干网络更换 ResNet50 能够提高分割精度，同时引入 DSConv 及注意力机制 ECA－Net 可使得分割精度进一步提升。

2.2　与不同模型在测试集上性能比较

为了验证改进的 U－Net 网络在无人机遥感图像中获取田间道路边界信息的效果，与几种常用的语义分割模型进行对比试验，包括 U－Net、

DeepLabV3 +[30]、Segformer[31]。DeepLabV3 + 使用编码器和解码器的架构,使用 Xception 作为主干网络,将深度可分离卷积应用到 ASPP 和解码器模块中,充分考虑速度和精度,在很多分割任务中获得了较高分割精度;Segformer 是将 Transfomer 与轻量级多层感知机解码器结合在一起,从而实现高效分割。这两个语义分割模型在处理分割任务上表现都十分优秀,与其进行测试对比从而验证改进 U - Net 在提取田间道路边界上的有效性。

图 7 为测试集上每个模型的分割可视化结果。由图 7 可知,大部分基准模型都存在田间道路识别不完整,有些基准模型甚至还存在错误分割的问题,改进 U - Net 模型识别效果最好,对田间道路边界信息获取更加完整、准确,具有较高的分割精度。

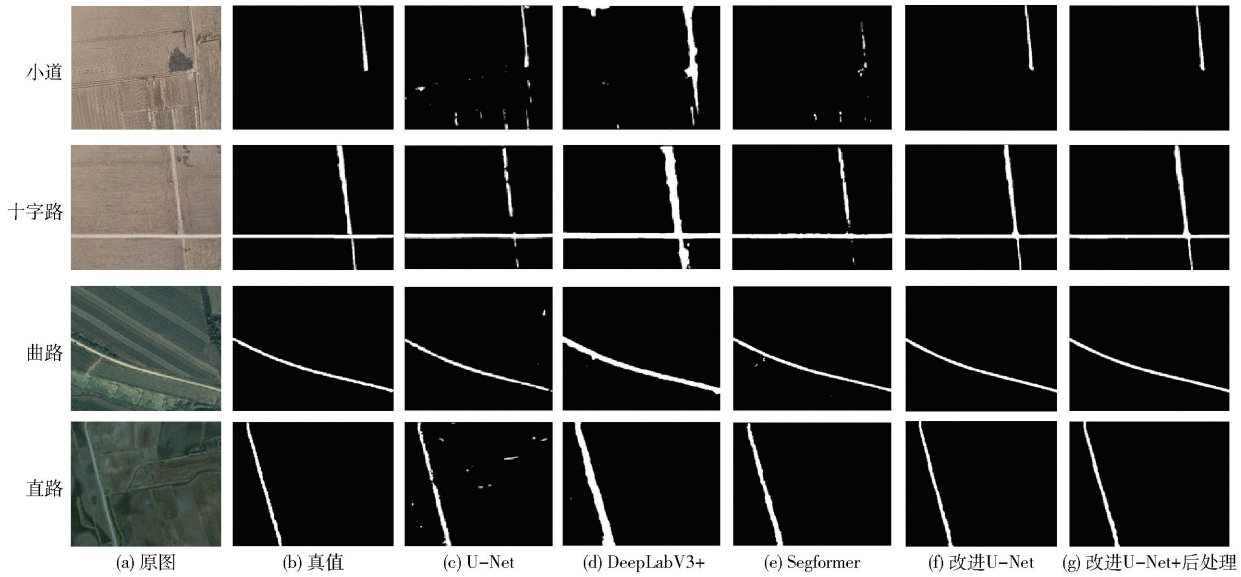

图 7 可视化结果对比

Fig. 7 Comparison of visualization results

表 3 为各模型对应的 MIoU、MPA 和参数量及每幅图像推理所花的平均时间。由表 3 可知,DeepLabV3 +、Segformer 在测试集上表现较差,而改进 U - Net 模型在所有模型中各项指标均较高,优于对照组模型。改进 U - Net 模型的 MIoU 分别比 DeepLabV3 +、Segformer 和 U - Net 高 20.69、19.31、5.96 个百分点。改进 U - Net 模型经后处理后,MIoU 为 92.64%,较未进行后处理提高 1.52 个百分点。

表 3 不同模型性能对比

Tab. 3 Comparison of test results of different models

模型	MPA/%	MIoU/%	参数量	推理时间/ms
改进 U - Net + 后处理	96.75	92.64	$5.669\,5\times10^7$	430.5
改进 U - Net	95.46	91.12	$5.669\,5\times10^7$	423.5
U - Net	89.40	85.16	$1.885\,4\times10^7$	478.5
DeepLabV3 +	72.66	70.43	$5.813\,0\times10^6$	492.6
Segformer	85.90	71.81	$3.715\,0\times10^6$	497.5

2.3 高分辨率正射影像图测试

农业高精度地图的制作需要获取相应的田间可行驶道路边界信息,地图制作需要使用高分辨率正射图,因此如何获取高分辨率正射影像图的可行驶道路信息是一个重要问题。由于高分辨率正射影像图的分辨率及存储问题,无法直接输入改进的语义分割模型进行田间可行驶道路的分割,难以直接获取高分辨率正射影像图的田间可行驶道路的边界信息。高分辨率正射影像图分割操作流程如图 8 所示,首先需要对高分辨率正射影像图进行分块,获取高分辨率正射影像图的分块图像,随后将其分别输入训练好的改进 U - Net 模型中进行预测分割,获得各块分割结果;最后将获得的各块分割结果进行合并,得到高分辨率正射影像图分割结果。

最终的部分高分辨率正射影像图分割可视化结果如图 9 所示,图 9a 原图为一幅分辨率为 4 121 像素 ×4 403 像素的正射影像图,具有单一的直行田间可行驶道路;图 9b 原图为一幅分辨率为 5 681 像素 × 11 606 像素的正射影像图,包含单一直行田间可行驶道路和多条直行田间可行驶道路交叉,形成较为复杂的田间可行驶道路网;图 9c 原图为一幅 2 692 像素 ×4 032 像素的正射影像图,包含 T 形田间可行驶道路;图 9d 为一幅 3 763 像素 ×3 889 像素的正射影像图,包含十字田间可行驶道路;图 9a 原 U - Net 的分割结果出现漏检问题,图 9b 原 U - Net 分割结果出现漏检问题导致田间可行驶道路出现间断,图 9c 原 U - Net 分割结果出现漏检及部分误检问

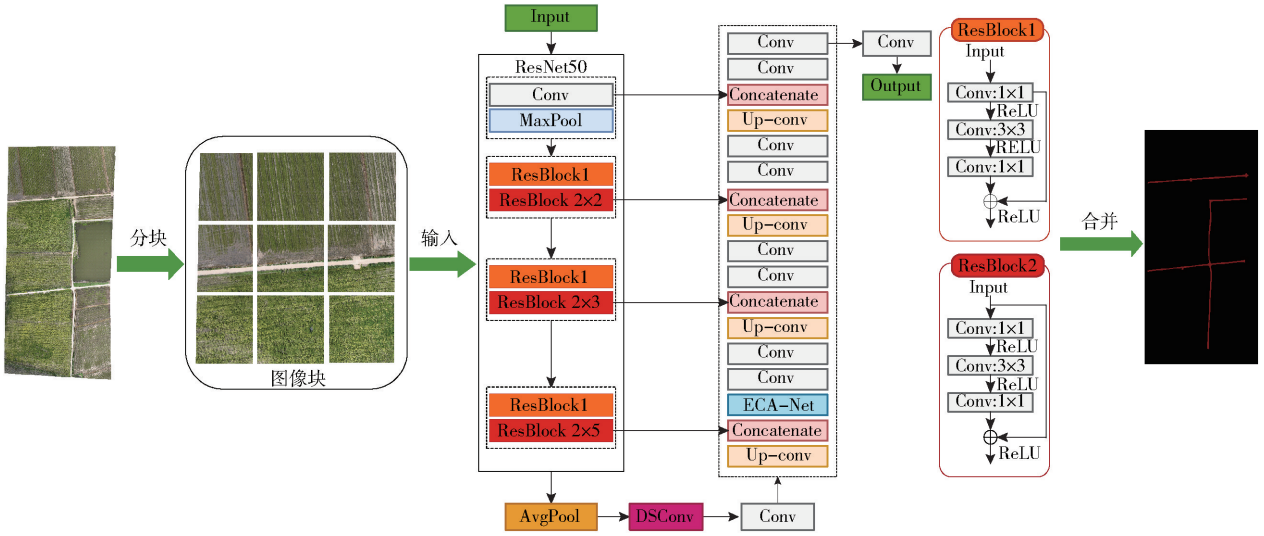

图 8　高分辨率正射影像图分割流程图

Fig. 8　High-resolution orthophoto map segmentation process

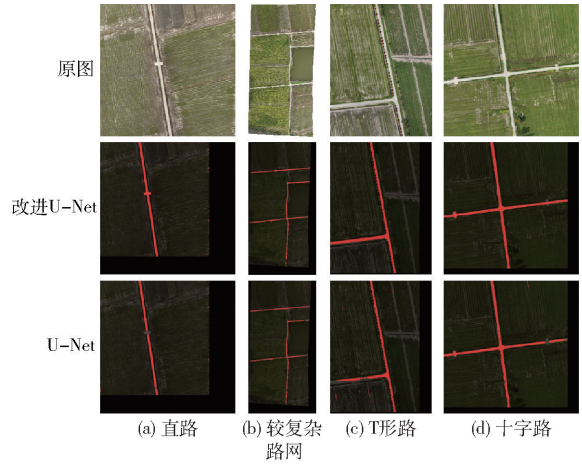

图 9　高分辨率正射影像图分割可视化结果

Fig. 9　Visualization results of high-resolution orthophoto map segmentation

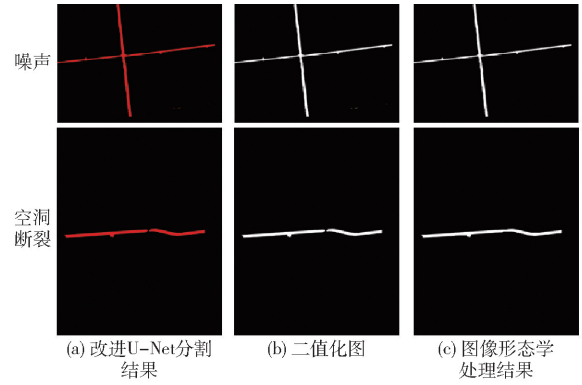

图 10　分割结果后处理

Fig. 10　Post processing of segmentation results

题，图 9d 原 U－Net 分割结果出现部分漏检问题，改进 U－Net 模型相比原 U－Net 分割可视化结果更加精确，无明显的漏分割和误分割问题，并且由表 4 可知改进 U－Net 模型推理时间与原 U－Net 相比相差不大，但各分割评价指标值比原 U－Net 模型更优。

表 4　高分辨率正射影像图对比试验结果

Tab. 4　Comparison test results of high-resolution orthophoto maps

模型	MPA/%	MIoU/%	推理时间/ms
改进 U－Net	90. 01	86. 39	2 440
U－Net	82. 37	80. 63	2 210

使用传统图像处理方法对最终的高分辨率正射影像图分割结果进行优化，如图 10a 所示，分割结果图中右下部分出现了误分割所导致的微小噪声，使用传统图像处理中图像形态学操作的开运算可以很好地消除这些微小噪声，同时对原分割结果不产生影响。图 10b 田间可行驶道路分割结果中间部分出现断裂空洞现象，使用图像形态学操作中的闭运算来解决图中出现的空洞断裂现象，使得断裂道路连接起来。如表 5 所示，经后处理后 MPA 和 MIoU 分别为 91. 53% 和 88. 34%。与改进 U－Net 模型相比，传统图像处理方法优化了高分辨率正射影像图的分割结果，MPA 和 MIoU 分别提高 1. 52、1. 95 个百分点。

表 5　后处理试验结果

Tab. 5　Post processing test results　%

模型	MPA	MIoU
改进 U－Net	90. 01	86. 39
改进 U－Net＋后处理	91. 53	88. 34

2. 4　讨论

本文所提方法可用于农场田间可行驶道路信息的提取，为无人农场构建高精度地图提供可用的道路信息。在模型训练过程中均采用 Cos 策略来对学习率进行调整，防止过拟合现象，同时使用 Adam 进行优化，并采用 Dice_Loss 损失函数解决田间可行驶

道路占比少所导致的类别不平衡问题。根据高分辨率正射影像图试验结果,改进 U-Net 网络经后处理优化后,MIoU 和 MPA 分别为 88.34% 和 91.53%,分割精度达到制作农田高精度地图道路层的要求,可避免人工在田间进行打点采集的繁琐耗时工作,大大节省人力及时间。高分辨率正射影像图通过该方法所提取出的田间可行驶道路经过后续制作,可获得相应的图层 shp 文件,作为农田高精度地图中的道路边界信息,通过远程管控平台对农机终端进行数据及指令下发,协助农机进行田间路径规划。

本研究仍存在一些不足:首先,虽然对 U-Net 模型进行了相应改进,并且对应的评价指标均优于其他基准网络模型,基本可以实现高分辨率正射影像图田间可行驶道路的识别,但在进行语义分割时仍有少量道路未识别准确。其次,改进 U-Net 模型的参数量明显高于其他模型,但模型平均推理时间并无显著变长,可能因为改进 U-Net 模型采用的 ResNet 主干网络的残差块能有效地减少在深层网络结构中产生的新计算量,ResNet 架构采用的瓶颈层可以在进行卷积操作前有效地减少特征图产生的数量,可通过减少卷积操作降低模型总体计算量。最后,在部署及打包时相较于其他网络更加占用内存,不利于模型迁移到其他设备上,后续可以考虑对改进 U-Net 模型进行进一步轻量化改进,在不降低分割精度的情况下,使得模型更加轻量化,能够更好地进行部署及打包。

3 结论

(1)提出基于改进 U-Net 的田间可行驶道路分割方法,通过更换主干网络为 ResNet50 来增强编码器对田间可行驶道路的特征提取能力,融合可以提高管状结构精度的 DSConv 模块提高对田间可行驶道路的识别精度,并抑制与田间道路类似的田间地物背景的特征提取,最后在解码器中引入 ECA-Net 优化田间可行驶道路的特征还原过程,从而提高模型的整体分割精度。

(2)该分割方法在田间可行驶道路测试集上的 MIoU 为 91.12%,相较于原 U-Net 提高 5.96 个百分点,且高于 DeepLabV3 +、Segformer,平均每幅图像推理时间为 423.5 ms。通过传统图像处理方法处理后,MIoU 为 92.64%,较未进行后处理提高 1.52 个百分点。

(3)基于高分辨率正射影像图进行分割精度测试,改进 U-Net 模型的 MIoU 和 MPA 分别为 86.39% 和 90.01%,高于原 U-Net,分割精度 MIoU 及 MPA 分别提高 5.76、7.64 个百分点。应用传统图像处理方法对高分辨率正射影像分割结果图中出现噪声及田间可行驶道路断裂现象进行优化,消除细小噪声及空洞断裂现象,最终获得的 MIoU 和 MPA 为 88.34% 和 91.53%,与未使用前相比分别提高 1.95、1.52 个百分点。该方法可以为后续农田高精度地图构建提供准确的田间道路边界信息,为农田高精度地图图层制作提供支持。

参 考 文 献

[1] 王宁,韩雨晓,王雅萱,等. 农业机器人全覆盖作业规划研究进展[J]. 农业机械学报,2022,53(增刊 1):1-19.
WANG Ning, HAN Yuxiao, WANG Yaxuan, et al. Research progress of agricultural robot full coverage operation planning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(Supp. 1): 1-19. (in Chinese)

[2] WANG N, YANG X, WANG T, et al. Collaborative path planning and task allocation for multiple agricultural machines[J]. Computers and Electronics in Agriculture, 2023, 213: 108218.

[3] YANG L, XU Y, LIANG Y, et al. Extraction of straight field roads between farmlands based on agricultural vehicle-mounted LiDAR[J]. International Journal of Agricultural and Biological Engineering, 2022, 15(5): 155-162.

[4] 杨丽丽, 陈炎, 田伟泽, 等. 田间道路改进 UNet 分割方法[J]. 农业工程学报, 2021, 37(9): 185-191.
YANG Lili, CHEN Yan, TIAN Weize, et al. Field road segmentation method based on improved UNet[J]. Transactions of the CSAE, 2021, 37(9): 185-191. (in Chinese)

[5] WANG T, WANG N, XIAO J, et al. One-shot domain adaptive real-time 3D obstacle detection in farmland based on semantic-geometry-intensity fusion strategy[J]. Computers and Electronics in Agriculture, 2023, 214: 108264.

[6] 黄亮,吴春燕,李小祥,等. 基于弱监督语义分割的灯盏花无人机遥感种植信息提取[J]. 农业机械学报,2022,53(4):157-163.
HUANG Liang, WU Chunyan, LI Xiaoxiang, et al. Extraction of *Erigeron breviscapus* planting information by unmanned aerial vehicle remote sensing based on weakly supervised semantic segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 157-163. (in Chinese)

[7] HUANG J, LUO Y, QUAN Q, et al. An autonomous task assignment and decision-making method for coverage path planning of multiple pesticide spraying UAVs[J]. Computers and Electronics in Agriculture, 2023, 212: 108128.

[8] ILNIYAZ O, DU Q, SHEN H, et al. Leaf area index estimation of pergola-trained vineyards in arid regions using classical and deep learning methods based on UAV-based RGB images[J]. Computers and Electronics in Agriculture, 2023, 207: 107723.

[9] LU H, WANG H, MA Z, et al. Farmland boundary extraction based on the AttMobile-DeeplabV3 + network and least squares fitting of straight lines[J]. Frontiers in Plant Science, 2023, 14: 1228590.

[10] CALISKAN E, SEVIM Y. Forest road extraction from orthophoto images by convolutional neural networks[J]. Geocarto International, 2022, 37(26): 11671－11685.
[11] KERKECH M, HAFIANE A, CANALS R. Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach[J]. Computers and Electronics in Agriculture, 2020, 174: 105446.
[12] 杨福增,袁敏鑫,许翔虎,等. 基于改进 TransUNet 的黄土高原梯田作业区域提取方法[J]. 农业机械学报,2024,55(12):278－286.
YANG Fuzeng, YUAN Minxin, XU Xianghu, et al. Extraction method of terrace operation area in Loess Plateau based on improved TransUNet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 278－286. (in Chinese)
[13] YI S, LI J, JIANG G, et al. CCTseg: a cascade composite transformer semantic segmentation network for UAV visual perception[J]. Measurement, 2023, 211: 112612.
[14] XU B, FAN J, CHAO J, et al. Instance segmentation method for weed detection using UAV imagery in soybean fields[J]. Computers and Electronics in Agriculture, 2023, 211: 107994.
[15] 武锦龙,吴虹麒,李浩,等. 基于改进 DeepLabV3＋的荞麦苗期无人机遥感图像分割识别方法研究[J]. 农业机械学报,2024,55(5):186－195.
WU Jinlong, WU Hongqi, LI Hao, et al. Segmentation of buckwheat by UAV based on improved lightweight DeepLabV3＋ at seedling stage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 186－195. (in Chinese)
[16] 胡根生,谢一帆,鲍文霞,等. 基于轻量型网络的无人机遥感图像中茶叶枯病检测方法[J]. 农业机械学报,2024,55(4):165－175.
HU Gensheng, XIE Yifan, BAO Wenxia, et al. Lightweight network for tea leaf blight detection in UAV remote sensing images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4): 165－175. (in Chinese)
[17] 杨蜀秦,林丰山,徐鹏辉,等. 基于无人机遥感影像的多生育期冬小麦种植行检测方法[J]. 农业机械学报,2023,54(2):181－188.
YANG Shuqin, LIN Fengshan, XU Penghui, et al. Planting row detection of multi-growth winter wheat field based on UAV remote sensing image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 181－188. (in Chinese)
[18] ZHANG Z, LIU Q, WANG Y. Road extraction by deep residual U－Net[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(5): 749－753.
[19] HU J, GAO J, YUAN Y, et al. LGNet: location-guided network for road extraction from satellite images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1－12.
[20] 袁翠霞,赵春江,任艳敏,等. 基于 U－Net 网络的高标准农田道路识别方法[J]. 农业机械学报,2023,54(5):163－169,218.
YUAN Cuixia, ZHAO Chunjiang, REN Yanmin, et al. Recognition method of high-standard farmland road based on U－Net[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 163－169, 218. (in Chinese)
[21] 李法霖,石军锋,梁新成,等. 基于改进 DeepLabV3＋的丘陵田间道路图像分割方法研究[J]. 西南大学学报(自然科学版),2024,46(8):172－183.
LI Falin, SHI Junfeng, LIANG Xincheng, et al. Research on hilly field road image segmentation method based on improved DeepLabV3＋[J]. Journal of Southwest University (Natural Science Edition), 2024, 46(8): 172－183. (in Chinese)
[22] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-assisted Intervention-MICCAI 2015: 18th International Conference, 2015: 234－241.
[23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770－778.
[24] QI Y, HE Y, QI X, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 6070－6079.
[25] WANG Q, WU B, ZHU P, et al. ECA－Net: efficient channel attention for deep convolutional neural networks[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534－11542.
[26] LOSHCHILOV I, HUTTER F. SGDR: stochastic gradient descent with warm restarts[J]. arXiv Preprint, arXiv:1608.03983, 2016.
[27] KINGMA D P, BA J. Adam: a method for stochastic optimization[J]. arXiv Preprint, arXiv:1412.6980, 2014.
[28] 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.
[29] HAN K, WANG Y, TIAN Q, et al. Ghostnet: more features from cheap operations[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580－1589.
[30] 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.
[31] XIE E, WANG W, YU Z, et al. SegFormer: simple and efficient design for semantic segmentation with transformers[J]. Advances in Neural Information Processing Systems, 2021, 34: 12077－12090.