

基于改进 U-Net 的遥感影像农作物提取^①



周 林, 武黎黎, 李 响

(安徽农业大学, 合肥 230036)

通信作者: 武黎黎, E-mail: wulili@ahau.edu.cn

摘 要: 我国作为一个人口众多的农业大国, 农作物的种植面积在预测我国的粮食产量和确保粮食安全方面起着至关重要的作用. 但是传统图像分割技术在提取遥感影像中地物信息时耗时费力, 且未必能达到好的效果, 为解决此类问题, 本文用深度学习研究方法对高清遥感影像中的多种农作物进行精细化分类提取, 本研究以合肥市周边地区农田中的水稻、玉米、大豆这 3 种农作物为实验样本. 在研究中, 本文提出一种改进的 U-Net 网络模型来对农作物进行提取的方法, 使提取精度达 94.86%. 为了实现对农作物边界的进一步优化, 本文使用 CascadePSP 边缘优化算法对实验结果进行细化, 使提取精度高达 96.72%. 实验结果表明, 本文的改进 U-Net 与 CascadePSP 算法结合, 使高清遥感影像中农作物的提取效果, 优于大多数深度学习模型.

关键词: 深度学习; 遥感影像; U-Net; 农作物

引用格式: 周林, 武黎黎, 李响. 基于改进 U-Net 的遥感影像农作物提取. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9880.html>

Crop Extraction from Remote Sensing Images Based on Improved U-Net

ZHOU Lin, WU Li-Li, LI Xiang

(Anhui Agricultural University, Hefei 230036, China)

Abstract: The crop cultivation in China, a populous agricultural nation, plays a vital role in predicting national grain yield and ensuring food security. However, traditional image segmentation techniques are time-consuming and laborious in extracting ground object information from remote sensing images, and may not achieve good results. To solve such problems, this study uses deep learning methods to conduct refined classification and extraction of various crops from high-resolution remote sensing images. In this study, rice, corn, and soybean crops in farmland around Hefei City are taken as experimental samples. In this study, an improved U-Net-based network model for crop extraction is proposed, achieving an extraction accuracy of 94.86%. To further optimize crop boundaries, the CascadePSP edge optimization algorithm is used to refine the experimental results, elevating the accuracy to 96.72%. The experimental results show that the improved U-Net model combined with the CascadePSP algorithm outperforms most deep learning models in extracting crops from high-resolution remote sensing images.

Key words: deep learning; remote sensing image; U-Net; crop

粮食安全不仅是国家安全不可或缺的基石, 更是国民经济稳健发展的支柱以及构建人类和谐社会的坚实物质基础. 2023 年 5 月联合国粮农组织公布了《全球粮食危机报告》, 报告指出 2022 年全球 58 个国家

和地区的大约 2.58 亿人面临着严峻的粮食安全威胁, 这一数字比 2021 年的 53 个国家和地区的 1.93 亿人有所上升, 2022 年面对严峻的粮食安全问题以及急需食物、营养和生计支持的人群数量连续第 4 年上升, 危

^① 基金项目: 国家自然科学基金 (42171333)

收稿时间: 2024-08-26; 修改时间: 2024-11-29; 采用时间: 2025-01-21; csa 在线出版时间: 2025-04-30

机人数达到了该年度报告发布以来 7 年的最高点^[1]。面对粮食安全挑战,能够迅速获取农作物种植种类和面积,对评估农作物和粮食的产出并帮助决策者更好制定决策以满足当地的粮食需求尤为关键^[2]。

我国是一个人口众多、耕地面积有限的发展中的农业大国,粮食的安全问题对我国的社会稳定、国家安全以及其他一系列关键性战略议题都产生了深远的影响^[3]。我国是全球范围内最大的粮食生产、消费和进口大国^[4]。农作物种植的种类和面积是我国对粮食产量监测和安全保障评估的关键数据,准确及时地获取这些数据对于我国社会经济发展、相关战略制定、农产品进出口计划的规划、农业结构调整与指导、个体种植户以及相关企业的种植管理水平提升、国家粮食安全保障等方面均具有重大意义^[5]。

遥感科学技术因其能够快速识别地物类的信息而被广泛地应用于多个领域,经过多年的技术迭代升级,遥感技术在空间和时间分辨率上都取得了显著提升。先进的航天遥感技术为科学研究提供了大量宏观和实时数据,以监测全球和区域环境的变化^[6]。我国从 2013 年开始发射了多颗可用于科研的高清卫星,这些卫星拍摄的高分辨率遥感数据在环境资源、农业等相关领域得到了广泛的应用,不仅促进了各个领域业务的发展,也为相关科学研究提供了宝贵机会^[7]。目前遥感技术已经广泛用于农作物的提取,比如,张文文等^[8]研究提取高分 2 号高清遥感影像中的水稻时提出一种基于 U-Net 改进的 F-UNet 方法使实验精度达到 92.1%。李世华等^[9]提出一种基于 Sentinel-1 SAR 卫星数据和遥感云计算结合的方法,来提取四川盆地水稻种植面积,其实验精度达到 82.08%。吕伟等^[10]在 Sentinel-1 SAR 和 Sentinel-2 MSI 遥感影像中的玉米种植面积提取的实验中,得出使用卷积神经网络提取的效果要优于使用随机森林的方法,能使精度达到 93.33%。目前,在基于遥感影像提取农作物的研究中,对单一类农作物提取的研究较多,但对多种农作物同时进行精细化分类提取的研究较少。

随着计算机技术的发展,机器学习领域衍生出深度学习相关技术^[11]。深度学习是机器学习的一个分支^[12]。传统机器学习在处理复杂函数的能力上存在局限性,学习水平也不是很高,因此处理复杂问题时的泛化能力受到了一定的限制^[13]。而深度学习弥补了这些不足,可以使模型更好地理解和处理各种复杂的数据。目前

深度学习技术已大量应用于高清遥感图像的目标识别检测和语义分割领域,并且已经得到了广泛的应用^[14]。

1 数据来源

本文实验数据所使用的遥感影像来自高分 2 号卫星拍摄的合肥地区 2023 年 7-8 月间的农田影像。本研究进行大量数据调查,并结合谷歌地球(GEE 平台)和高分 2 号遥感卫星数据,采用实地勘测和目视解译的相结合的方法找出高分 2 号遥感数据中的水稻、玉米、大豆的真实值。

2 改进的 U-Net 模型

U-Net 模型是由 Ronneberger 等^[15]提出的用于医学影像分割的深度学习神经网络,其架构呈现一个 U 形。U-Net 模型是一种常见的编码解码器结构模型^[16]。本文在 U-Net 模型的基础上进行改进,提出一种基于改进 U-Net 网络对农作物进行提取的方法,在 U-Net 编码器中添加 CNN 和 Transformer 结构增加下采样能力,在 U-Net 解码器中添加多层融合校验机制,每一层添加一个校验层。改进的 U-Net 网络提升了对特征的识别能力,减少了多次深度采样造成的特征丢失问题。网络模型如图 1 所示。

2.1 添加 CNN-Transformer 混合结构

传统的 CNN 卷积神经网络拥有更好的局部感知能力,它还拥有局部空间信息,不同的卷积核拥有不同的感受视野,但是它的不足之处在于不能对全局信息进行很好的综合把控,池化层会失去某些特性信息、部分特征和全局环境之间的联系。Transformer 网络更关注于对全局信息的特征提取,但是它的不足之处在于对细节信息的提取能力相对较弱。为此,本论文在实验中将 CNN 和 Transformer 都添加到 U-Net 网络模型中,在编码端采用 CNN 与 Transformer 混合架构,其中 CNN 作为特征抽取者,对特征进行卷积处理,从而获得精细、高精度的数据信息。此外 Transformer 还将自适应机制引入到编码端,利用其内在的自注意力机制克服由于卷积处理而不能进行远程建模的局限。

在原始 U-Net 模型的编码-解码器中添加了 CNN 与 Transformer 层,CNN 的底层网络使用 ResNet50 代替,Transformer 的底层图像使用 ViT 代替,输入 U-Net 网络的图像数据首先经过 CNN,对输入数据在下采样

过程中做3次卷积运算,每一次卷积运算后得到的特征图大小缩小为前一次的一半,分别得到原图大小的1/2, 1/4和1/8,将输出结果按给定大小输出到每个映射的向量序列中.再将数据输入到Transformer层中进行12次循环.改进后的U-Net模型将输入的数据先送入CNN卷积神经网络中提取图像特征,提取完采样的特征数据后,生成对应的特征图,将其转换为二维矩阵的图像补丁,对其位置进行编码,再将其映射到对应的

输出空间中. Transformer编码器包含归一化操作(layer normalization)、多头自注意力模块(multi-head self-attention)、多层感知机(multilayer perceptron).多头自注意力模块中的QKv(query-key-value)是一种常见的注意力机制,其基本思想是通过输入数据进行加权求和,来实现不同位置的关注程度,其计算公式如下:

$$Attention(Q, K, v) = Softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)v \quad (1)$$

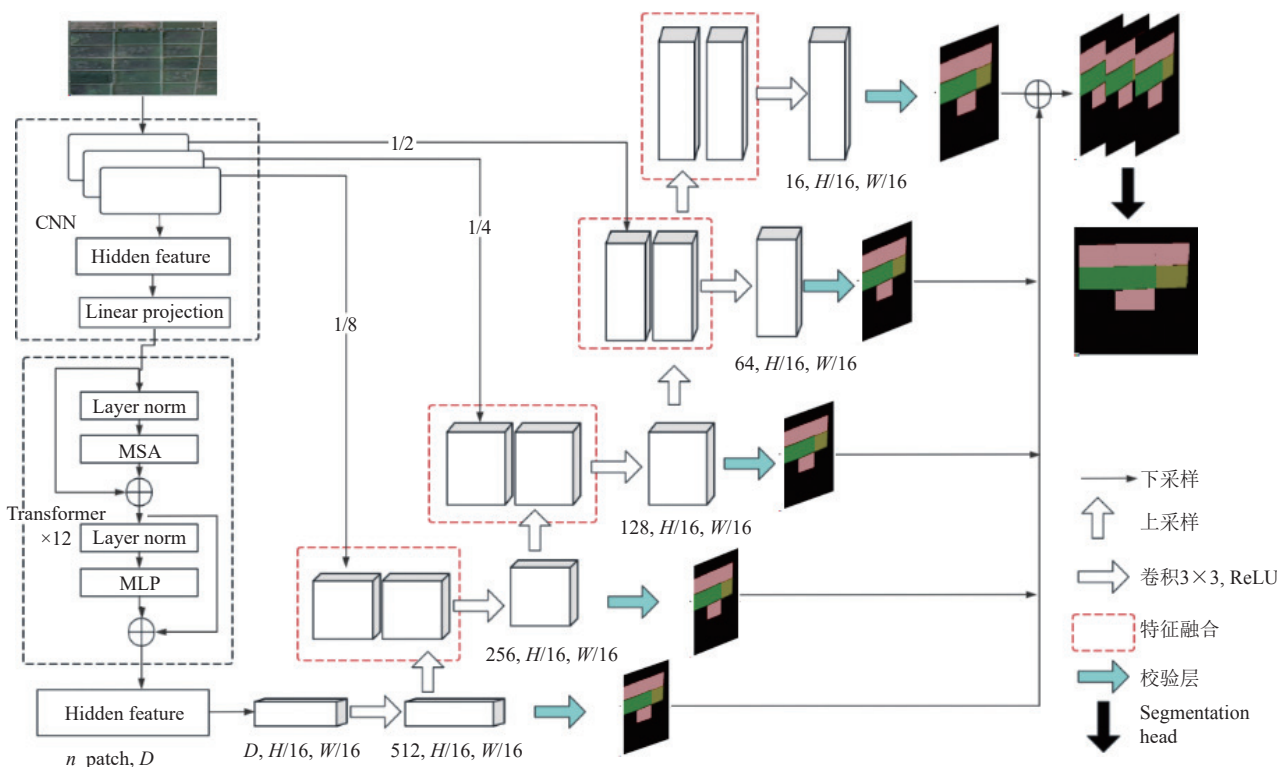


图1 模型结构图

使用LN代表归一化操作,MSA代表多头自注意力,MLP代表多层感知机,在网络编码器中第x层的输出数据,如式(2)、式(3)所示:

$$z'_x = MSA(LN(z_{x-1})) + z_{x-1} \quad (2)$$

$$z_x = MLP(LN(z'_x)) + z'_x \quad (3)$$

LN是一种常用的归一化技术,用于神经网络模型中的层级归一化操作.它在每个样本的每个特征维度上进行归一化,可以缓解网络中出现的梯度消失和梯度爆炸问题,还可以提高模型训练的速度和准确性.用 m_l 代表输入层的均值, n_l 代表输入层的方差, a 和 b 为偏置参数,为防止分母为0设置参数 t ,则计算公式如

式(4)所示:

$$LN(x_i) = \frac{x_i - m_l}{\sqrt{n_l + t}} \times a + b \quad (4)$$

解码器和U-Net结构一样,由上采样层、卷积层和ReLU激活函数构成.上采样过程中解码器会融合CNN输出的不同特征图像,最终恢复原有图片大小.

2.2 添加多层融合校验机制

在U-Net模型训练过程中,在解码过程中随着上采样层次的加深也会导致一些特征数据的丢失,因此本文在改进的U-Net模型中添加多层融合校验机制,确保U-Net每一个网络层的语义特征数据都能被很好地运用.

在解码器上采样过程中,每一层最后添加一个校验层,每个校验层由1个上采样层、1个3×3的卷积层及 Sigmoid 激活函数层组成,如图2所示,在处理特征数据的过程中,先将解码的隐藏层(hidden feature)的特征数量调整为几种农作物的类别数量,接着执行双线性插值的上采样操作,恢复输入图像数据的尺寸大小.在解码器的最后阶段将校验层的结果进行图像融合,得到最终输出数据.添加多层融合校验机制的网络可以对解码过程中各个层级的网络特征数据进行监督,防止特征丢失,实现对每一层特征的充分利用,对农作物特征进行更完整的提取.




图2 校验层

2.3 CascadePSP 边界优化算法

CascadePSP 算法提出于 2020 年, CascadePSP 是

为了解决现有图像分割算法主要在固定分辨率范围内进行训练、对于高分辨率图像的分割效果不理想、无法准确捕获高分辨率图像的边界细节、训练高分辨率图像对 GPU 的内存要求较高等问题. CascadePSP 算法主要使用 ResNet50 和 PSPNet 作为主干网络,来负责图片的特征提取任务.该算法通常级联于其他分割算法之后,作为特征细化和修复模块. CascadePSP 算法的输入包含原始的 RGB 图像和分割后的结果,可以由不同尺寸大小的分割结果图片组成,对其进行叠加,使用不同阶段的结果作为输入实现级联. ResNet50 连接金字塔池化的头部,根据输入的特征图像,在主干网络的上采样过程中实现特征融合,并恢复图像的尺寸大小,网络结构中添加跳跃层可以有效防止特征信息的丢失. CascadePSP 算法的输出不再是单尺度的结果,而是分 3 个阶段输出 OS8、OS4、OS1 这 3 种尺度大小,可以实现最精细的边缘提取结果. CascadePSP 算法细化模块的网络结构如图3所示.

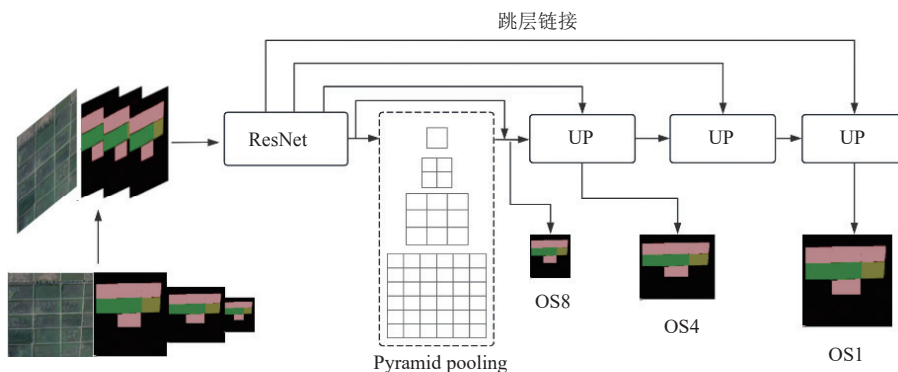


图3 CascadePSP 网络模块结构图

CascadePSP 算法可以将任意给定的图像分割从低分辨率细化到高分辨率,通过全局和局部的细化过程,实现更精细的图像分割. CascadePSP 具有即插即用的特点,可以直接接入现有的深度学习图像分割算法中,对分割模块做局部或者全局修正,该修正过程可以针对不同类型的图像和分割任务进行定制,以满足不同应用需求,在不增加计算复杂度的前提下能显著提高图像分割的精度和效果.

基于 CascadePSP 算法的优点和特性,本实验选用 CascadePSP 算法对实验结果进行更精细的优化,将其附加到本实验改进的 U-Net 模型中,用于生成更加精细化的分割掩码,对农作物分割结果进行全局和局部的细化,从而实现多种农作物边界更精细化的修正.本

文将 CascadePSP 算法优化实验结果与传统边缘检测算子优化结果进行对比分析,找出高分 2 号遥感影像中水稻、玉米和大豆 3 种农作物提取的最佳方法.

3 实验过程与对比

3.1 实验环境

本研究的实验需要在服务器上运行,服务器的配置如表1所示.

3.2 实验思路

本文对高分 2 号遥感影像中合肥市周边地区农田中的水稻、玉米、大豆 3 种农作物进行提取.采取人工勘测和目视解译相结合的方式找出 3 种农作物的真实值.实验使用目前常用的几种深度学习模型 SegNet、

DeepLabv3+、U-Net 与本文改进的 U-Net 模型进行实验对比,找出提取农作物效果最好的深度学习模型,接着使用最优深度学习模型结合常用的 3 种边缘检测算子 Canny、Susan、Sobel 及 CascadePSP 边界优化算法,对农作物的边界进一步优化,找出识别农作物的最佳方法.实验流程如图 4 所示.

表 1 服务器环境配置

名称	配置参数
CPU	Intel(R) Xeon(R) Gold 6226R @ 2.90 GHz
GPU	Tesla V100 32 GB
内存	32 GB
硬盘	8 TB
操作系统	Linux
软件版本	PyTorch 1.7

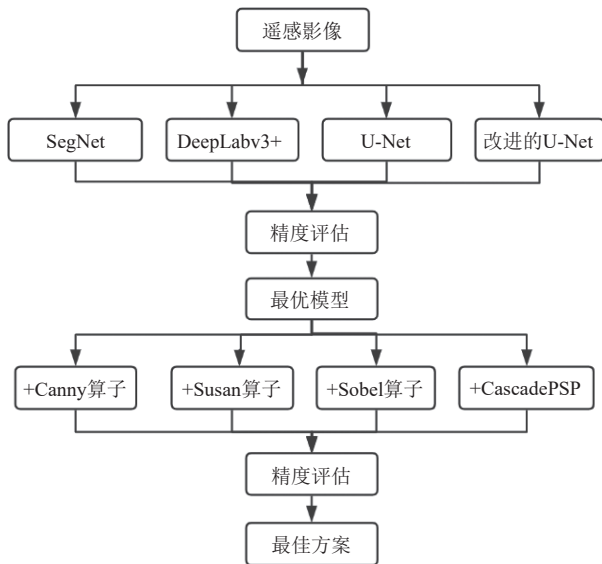


图 4 实验流程图

3.3 评价指标

用 4 种深度学习模型提取合肥市农田中的农作物后,需要使用目视解译方法和具体的深度学习评价模型来确定模型的提取情况.由于不同模型之间存在着差异,所以在应用过程中需要结合特定的分类标准才能得到正确的提取结果,并对结果进行评价.通过科学且高效的评估手段可以对每个模型做出全面和客观地评估,同时也论证了最佳提取方法的全面可靠性.为了对本实验进行科学性的评价,使用精度 (*Precision*)、召回率 (*Recall*)、平均交并比 (*MIoU*) 来评价深度学习模型对于提取合肥市地区农作物的准确性以及适用性.混淆矩阵定义如表 2 所示.

表 2 混淆矩阵

样本类别	正样本 (Positive)	负样本 (Negative)
正样本 (True)	TP: 预测农作物为真	TN: 预测背景为真
负样本 (False)	FP: 预测背景为农作物	FN: 预测农作物为背景

精度 (*Precision*), 又被称为用户精度, 代表预测结果是正类样本中真实样本的数目^[17], 模型提取结果的正确性可以通过其精度来体现, 通常模型的精确度越高, 该模型表现就越出色, 数学表达式如式 (5) 所示:

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

召回率 (*Recall*), 用来衡量模型能够识别所有目标对象的能力, 也就是说, 模型提取出的实际目标对象的数量^[17]. 一般而言, 召回率数值越高, 意味着该模型检测出的农作物就会越多, 数学表达式如式 (6) 所示:

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

平均交并比 (*MIoU*), 用来比较真实值和预测值之间重叠的百分比, 该指标常用于目标检测任务中, 在农作物识别中表示提取结果像素集合与真实像素集合的交集和并集的比值. 数学表达式如式 (7) 所示:

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

3.4 实验与分析

为验证深度学习模型提取合肥市地区农作物数据的可适用性, 本文基于高分 2 号遥感影像数据集, 分别将深度学习模型 SegNet^[8]、DeepLabv3+^[18]、U-Net^[8] 和本文改进的 U-Net 模型在提取水稻、玉米和大豆 3 种农作物方面进行了对比和分析. 如图 5 所示, 选取了 3 张都包含水稻、玉米、大豆的 3 种农作物图片. 其中, 第 1 列是原始图片, 第 2 列是 Label 标签, 第 3–5 列分别是 SegNet、U-Net、DeepLabv3+ 这 3 种深度学习模型的提取结果, 最后一列是本文改进的 U-Net 深度学习网络模型提取的结果.

对比 4 种深度学习模型的识别结果可以看出, 每一种深度学习方法都可以识别出水稻、玉米和大豆 3 种农作物, 但存在许多细节性差异. 改进的 U-Net 模型在图 5 中没有出现识别错误的情况, 比其他 3 种模型对农作物提取的准确率要高, 而且可以较高程度地保留农作物田地间不规则的水渠或者小路, 识别的边界也比前 3 种模型较为清晰. SegNet 模型出现了将其其他类误判为水稻, 且对多种农作物交界处的混合像元

不能给出明确判断. U-Net 和 DeepLabv3+模型同样存在错误识别农作物的情况, 如图 5 中圆圈所表示的将其他农作物误识别为水稻, 这两种深度学习模型对农田之间界限明显的道路可以识别, 但对于小的道路或农作物交界处的识别效果并不理想, 有局部残缺的现

象. 由此识别结果可以看出, 改进的 U-Net 网络模型能更好地提取水稻、玉米和大豆 3 种农作物的种植区域, 能够更好地处理精细农作物中的光谱特征、纹理特征及空间特征等信息, 相比其他 3 种深度学习模型能够较好地保留农田间的道路和水渠等边界信息.

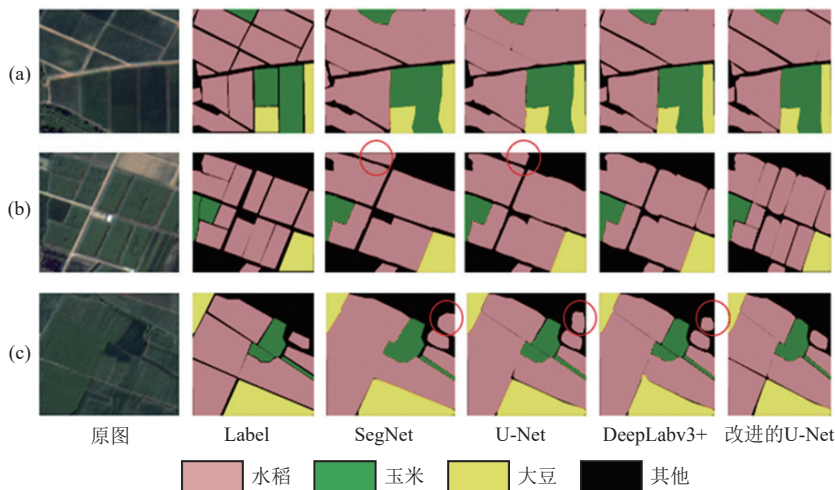


图 5 4 种深度学习模型的实验结果

由定性分析可得出, 本文改进的 U-Net 网络模型能够更准确地识别农作物, 再通过指标数据的定量分析比较 4 种深度学习模型提取农作物的能力, 表 3 展示了 4 种模型提取农作物的指标表现.

表 3 4 种实验结果对比表 (%)

模型	Precision	Recall	MIoU
SegNet	89.45	85.81	80.52
DeepLabv3+	92.03	88.07	85.16
U-Net	91.83	86.64	83.64
改进的U-Net	94.86	92.02	86.97

由各指标数据可以看出, 改进后的深度学习模型是 4 个方法中提取效果最好的, 提取水稻、玉米、大豆农作物的平均精度为 94.86%, 召回率为 92.02%, 平均交并比为 86.97%. 相比改进前的 U-Net 模型精度提高了 3.03%, 召回率提高了 5.38%, 平均交并比提高了 3.33%. 相比 DeepLabv3+模型精度提高了 2.83%, 召回率提高了 3.95%, 平均交并比提高了 1.81%. 相比 SegNet 网络模型精度提高了 5.41%, 召回率提高了 6.21%, 平均交并比提高了 6.45%. 直观指标对比如图 6 所示.

由实验结果可以得出本文改进的 U-Net 模型对农作物的提取效果相比其他 3 种模型更好. 为了找出对农作物的最佳提取方法, 本文在改进 U-Net 模型的基础上, 用 CascadePSP 边界优化算法与传统的 Canny、Susan、Sobel 这 3 种边缘检测算子分别进行农作物边

界优化实验, 探索农作物的边界优化问题. 实验结果如图 7 所示.

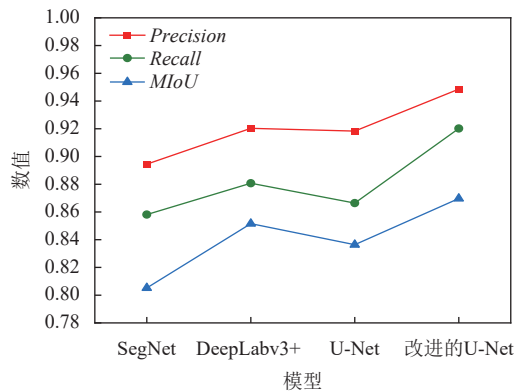


图 6 指标对比图

图 7 是从农作物提取结果中选取的 3 张具有代表性的图片示例, 第 1 张原始图片包含 3 种农作物且田地形状较为规整, 田间小路较为清晰. 第 2 张图片包含水稻和玉米, 农作物边界区分不明显且有阴影. 第 3 张图片包含 3 种农作物, 田地形状不规则, 小路纵横交错, 边界区分不明显. 实验效果从目视解译角度来说, 在农作物边界提取实验中, 改进的 U-Net 和 CascadePSP 边界优化算法结合的边界提取方法是所有实验结果中最好的. 对于第 1 张田地规整, 小的道路清晰的图像能做很好的边界区分; 对于第 2 张玉米和水稻边界不明显

且有阴影的图片,也能做很好的农作物边界提取;对于第3张地形复杂、田地成不规则形状且小路不清晰的图片,依然可以做出很好的边界区分.表4展示了实验结果的指标数据.

分析表4实验指标结果数据可以看出,与表3中单独使用改进的U-Net模型的实验指标结果对比,改进的U-Net和Canny边缘检测算子组合的实验结果接

近,变化幅度很小;改进的U-Net和Susan边缘检测算子组合的实验结果中,精度提升0.38%,召回率提升0.42%,平均交并比提升0.66%;改进的U-Net和Sobel边缘检测算子组合的实验结果中,精度提升0.73%,召回率提升0.71%,平均交并比提升1.51%;改进的U-Net和CascadePSP边界优化算法组合的实验结果中,精度提升1.86%,召回率提升2.8%,平均交并比提升3.78%.

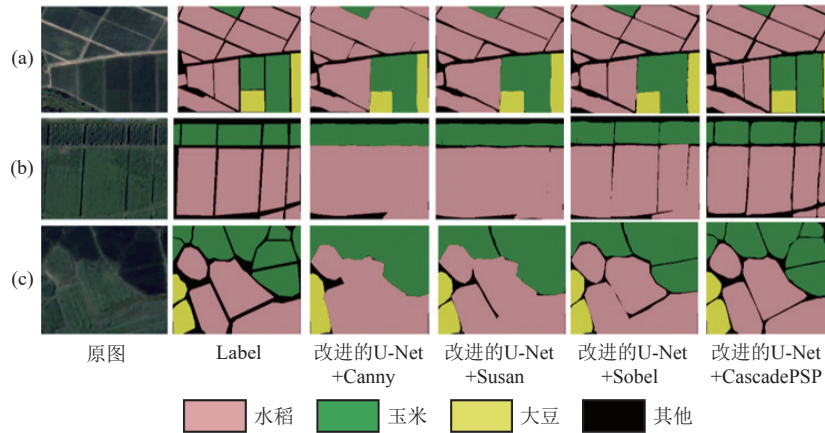


图7 不同边界优化方法的结果对比

表4 不同边界优化方法的精度对比 (%)

方法	Precision	Recall	MIoU
改进的U-Net+Canny	94.91	91.32	86.98
改进的U-Net+Susan	95.24	92.44	87.63
改进的U-Net+Sobel	95.59	92.73	88.48
改进的U-Net+CascadePSP	96.72	94.82	90.75

综合定性和定量的结果分析可以得出,本文改进的U-Net结合CascadePSP边界优化算法做局部优化的方法,在农田间存在植物交错复杂、阴影遮挡、不

规则小路贯穿等复杂环境下都可以对农作物进行准确的识别,且提取精度最高,是实验中最适用于农作物提取的方法.

使用本文改进的U-Net模型结合CascadePSP边界优化算法对一整幅遥感影像进行识别,如图8所示.图8(a)是一幅具有大量农田的高分2号卫星遥感影像,并且做了农作物的真值标记,拍摄的地面大小为23.5×23.5 km².图8(b)是使用本文方法所提取的水稻、玉米和大豆结果分布图.

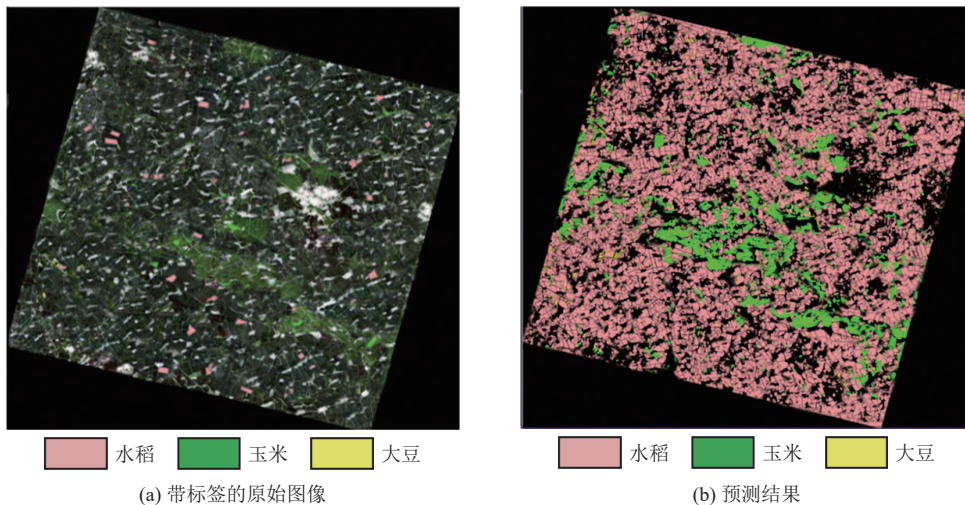


图8 一整张遥感影像的提取结果

4 结论

通过实验结果分析可以得出,在提取高分2号遥感影像中合肥市周边地区农田的水稻、玉米和大豆3种农作物时,本文所使用的4种深度学习模型的提取能力,由高到低排序依次为:本文改进的U-Net模型>DeepLabv3+>U-Net>SegNet。为了实现对农作物边界的进一步优化,本文使用CascadePSP算法和3种常见的边缘检测算子Canny、Susan、Sobel对提取农作物的实验结果进行进一步优化,得出本文改进的U-Net模型和CascadePSP算法的组合对于农作物边界优化的效果最好,精度达96.72%,该方法对于农田间存在植物交错复杂、阴影遮挡、不规则小路贯穿等复杂环境都可以进行很好的农作物边界提取,是一种适合从高清遥感卫星图像中提取农作物的方法。

参考文献

- 夏弦. “测量支撑全球粮食体系”主题会谈杭州举办. 中国食品报, 2023-05-17(07). [doi: [10.28137/n.cnki.ncsp.2023.000769](https://doi.org/10.28137/n.cnki.ncsp.2023.000769)]
- Lobell BD, Asner PG. Climate and management contributions to recent trends in U.S. agricultural yields. *Science*, 2003, 299(5609): 1032.
- 丑洁明, 董文杰, 徐洪, 等. 气候变化影响中国粮食安全研究的新思路. *气候与环境研究*, 2022, 27(1): 206–216. [doi: [10.3878/j.issn.1006-9585.2021.21148](https://doi.org/10.3878/j.issn.1006-9585.2021.21148)]
- 王新华. 我国粮食进出口、国内粮价与国际粮价的互动关系研究. *统计与决策*, 2013(14): 118–121.
- 陈仲新, 任建强, 唐华俊, 等. 农业遥感研究应用进展与展望. *遥感学报*, 2016, 20(5): 748–767.
- 明冬萍, 骆剑承, 沈占锋, 等. 高分辨率遥感影像信息提取与目标识别技术研究. *测绘科学*, 2005, 30(3): 18–20. [doi: [10.3771/j.issn.1009-2307.2005.03.004](https://doi.org/10.3771/j.issn.1009-2307.2005.03.004)]
- Kussul N, Lavreniuk M, Skakun S, *et al.* Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(5): 778–782. [doi: [10.1109/LGRS.2017.2681128](https://doi.org/10.1109/LGRS.2017.2681128)]
- 张文文. 基于遥感影像提取水稻种植区的方法研究 [硕士学位论文]. 泰安: 山东农业大学, 2021.
- 李世华, 刘开通, 何泽, 等. 基于遥感云计算平台的四川盆地水稻种植面积提取. *地理空间信息*, 2023, 21(12): 3–7.
- 吕伟, 宋轩, 杨欢. 基于深度学习和多源遥感数据的玉米种植面积提取. *江苏农业科学*, 2023, 51(23): 171–178.
- Ndikumana E, Ho Tong Minh D, Baghdadi N, *et al.* Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue, France. *Remote Sensing*, 2018, 10(8): 1217. [doi: [10.3390/rs10081217](https://doi.org/10.3390/rs10081217)]
- Holzinger A. From machine learning to explainable AI. *Proceedings of the 2018 World Symposium on Digital Intelligence for Systems and Machines (DISA)*. Košice: IEEE, 2018. 55–66.
- Bengio Y. Learning deep architectures for AI. *Foundations and Trends® in Machine Learning*, 2009, 2(1): 1–127.
- Maggiori E, Tarabalka Y, Charpiat G, *et al.* Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(2): 645–657. [doi: [10.1109/TGRS.2016.2612821](https://doi.org/10.1109/TGRS.2016.2612821)]
- Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. *Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention*. Munich: Springer, 2015. 234–241.
- Pravitasari AA, Iriawan N, Nuraini US, *et al.* On comparing optimizer of UNet-VGG16 architecture for brain tumor image segmentation. *Brain Tumor MRI Image Segmentation Using Deep Learning Techniques*. Amsterdam: Academic Press, 2022. 197–215.
- Pedrayes OD, Lema DG, Garcia DF, *et al.* Evaluation of semantic segmentation methods for land use with spectral imaging using Sentinel-2 and PNOA imagery. *Remote Sensing*, 2021, 13(12): 2292. [doi: [10.3390/rs13122292](https://doi.org/10.3390/rs13122292)]
- 姬晓飞, 张可心, 唐李荣. 改进DeepLabv3+网络的图书书脊分割算法. *计算机应用*, 2023, 43(12): 3927–3932.

(校对责编: 王欣欣)