

蒋元义,陈伟,王宏,等. 利用2米级卫星数据在喀斯特高原地区的油菜遥感监测[J]. 智能计算机与应用,2024,14(9):179-186. DOI:10.20169/j.issn.2095-2163.240928

利用2米级卫星数据在喀斯特高原地区的油菜遥感监测

蒋元义¹, 陈伟¹, 王宏¹, 陈涛¹, 张娇娇², 田凯凯²

(1 贵州省测绘资料档案馆, 贵阳 550001; 2 贵州黔聚龙科技有限公司, 贵阳 550081)

摘要: 喀斯特地貌使得贵州省耕地面积少,坡耕地多,油菜作为贵州省的主要农作物之一,其种植面积的准确评估对贵州省的农业管理具有重要意义。为解决高分辨率卫星数据获取成本高和喀斯特高原复杂地形带来的监测难题,本文以贵州省西秀区作为研究区,结合2米级卫星数据,通过实地测绘油菜为训练样本,基于卷积神经网络UNet++框架,构建了一种层次更深的残差网络ResNet-101模型自动提取油菜面积。试验结果表明,利用该网络模型来提取2米级卫星数据的油菜种植面积可行性较高,其面积统计精度和范围套合精度分别为99.69%、88.47%,达到相关部门统计油菜种植面积的精度要求。

关键词: 油菜种植面积; 喀斯特高原; 深度学习; 两米级卫星数据

中图分类号: S565.4; S127; TP181

文献标志码: A

文章编号: 2095-2163(2024)09-0179-08

Remote sensing monitoring of rapeseed in the karst plateau using two-meter satellite data

JIANG Yuanyi¹, CHEN Wei¹, WANG Hong¹, CHENG Tao¹, ZHANG Jiaojiao², TIAN Kaikai²

(1 Guizhou Provincial Archives of Surveying and Mapping Data, Guiyang 550001, China;

2 Guizhou Qianjulong Technology Co., Ltd, Guiyang 550081, China)

Abstract: The karst landscape makes Guizhou Province have less arable land and more sloping arable land, and as one of the main crops in Guizhou Province, the accurate assessment of the cultivated area of oilseed rape is of great significance to the agricultural management of Guizhou Province, in order to solve the monitoring difficulties brought by the high cost of acquiring high-resolution satellite data and the complex topography of the karst plateau. In this paper, Xixiu District of Guizhou Province is taken as the study area, combined with 2-meter satellite data, through field mapping of oilseed rape as a training sample, based on the convolutional neural network UNet++ framework, a deeper level residual network ResNet-101 model is constructed to automatically extract the area of oilseed rape. The experimental results show that it is highly feasible to use this network model to extract the oilseed rape planting area from 2-meter satellite data, and its area statistical precision and range fitting precision are 99.69% and 88.47%, respectively, which meets the precision requirements of the relevant departments for the statistics of oilseed rape planting area.

Key words: rape planting area; karst plateau; deep learning; two-meter satellite data

0 引言

作为菜籽油消费的重要国家,中国菜籽油消费量占据全球消费总量的四分之一以上,油菜产业的稳步发展对于保障中国食用植物油供应具有举足轻重的地位^[1]。贵州省的油菜种植面积在全国各省份中排名第五,每年种植的面积稳定在约700万亩,生产规模在全国范围内居于领先地位^[2]。喀斯特地貌在贵州分布广泛,占全省73.8%,贵州是中国

喀斯特地貌最为典型的地区之一。这种地貌使全省耕地面积少,坡耕地多,农业生产方式受到限制,阻碍了贵州现代化农业发展^[3]。

传统的油菜种植面积统计主要是通过实地测量调查或统计部门上报,与传统油菜种植面积统计方式相比,遥感监测成本低的同时具有更高的效率、精度和连续性^[4]。深度学习方法的出现为解决遥感数据处理这一难题提供了新的思路和方法^[5],卢廷玉^[6]在多源数据图像分类问题上,提出了CSNet、

基金项目: 贵州省科技厅重大专项计划(黔科合重大专项[2022]001)。

作者简介: 蒋元义(1992-),男,硕士,助理工程师,主要研究方向:遥感影像信息提取;王宏(1970-),男,学士,研究员,主要研究方向:摄影测量与遥感。

通讯作者: 陈伟(1989-),男,学士,工程师,主要研究方向:测绘地理信息。Email:gis_chen@qq.com

收稿日期:2024-07-11

MSSNet、A2Seg Net 和 DE-UNet 网络;王伟^[7]在图像分割中加入数据模点检测方法,取得了较好的分割精度;樊普^[8]提出了一种结合 Transformer 和 CNN 的地物分割方法,有效提升分割模型在边界处的效果;李梓瑜^[9]等提出一种基于 Adaptive Mixup 操作的深度残差分割网络,完成了复杂条件下的道路信息提取;陈佳慧^[10]等基于 CNN 与 ViT 混合结构,提出了一种有效的地物分类方法;何邦科等^[11]基于随机森林回归模型,提出了一种顾及遥感地表反射率、地形特征和观测几何信息的复杂地形区 FVC 遥感精细估算方法;蒋怡等^[12]基于高分六号影像通过最似然监督分类方法获取油菜种植空间分布信息;李杰等^[13]基于多源遥感数据研究了油菜种植面积提取方法。针对油菜识别,曾瑜等^[14]基于高分辨率无人机影像研究了 Deeplabv3、UNet 和 PSPNet 三种经典深度学习模型对盛花期油菜种植区的提取效果;杨泽宇等^[15]基于深度学习 CNN 和 RNN 神经网络模型方法提取冬油菜分布,结果表明基于深度学习的油菜遥感监测能准确的提取油菜范围。

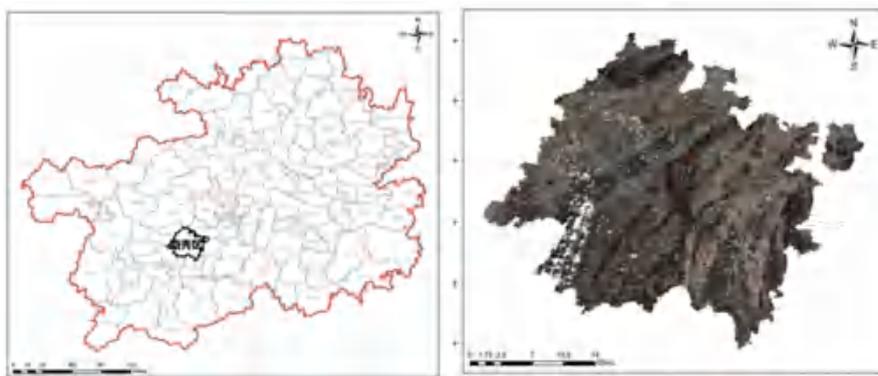
目前,针对复杂地形条件下的 2 米级卫星数据的油菜面积监测研究较少,本文以具有典型喀斯特

地貌的贵州省西秀区为研究区,利用 2 米卫星影像、外业调绘油菜图斑制作训练样本,通过卷积神经网络(UNet++)和深度残差网络(Resnet-101)构建模型自动识别油菜,并与 0.5 米、0.8 米卫星数据提取结果进行比较,用面积精度和套合精度两个评估指标对油菜面积提取结果进行评价。

1 研究区与数据源

1.1 研究区概况

选取贵州省安顺市西秀区为研究区,研究区矢量及遥感影像图如图 1 所示,该区位于贵州省中西部,介于东经 105°44'32"—106°21'58",北纬 25°56'30"—26°24'42",地处云贵高原东部、苗岭山脉西端,是典型的喀斯特高原地区,也是长江水系和珠江水系分水岭上的重要区域。区内气候温和宜人,四季鲜明,属于亚热带湿润气候区,年平均气温适中,为油菜的生长和发育提供了有利条件。油菜作为当地农业的重要支柱产业之一,其种植规模持续扩大。根据第三次全国国土调查数据,西秀区耕地面积为 58 343.57 公顷(即 87.52 万亩),其中油菜种植面积为 30.683 2 万亩^[16]。



研究区矢量图

研究区遥感影像图

图 1 研究区矢量及遥感影像图

Fig. 1 Vector and remote sensing image map of the study area

1.2 数据源及预处理

根据需求确定了合适的卫星平台和数据来源,获取了覆盖西秀区 0.5 米分辨率影像 26 景,为吉林一号卫星影像,时相集中在 2024 年 2 月 20 日;0.8 米分辨率影像 18 景,为高分二号、北京二号、北京三号卫星影像,时相集中在 2024 年 4 至 5 月;2 米分辨率影像 1 景,为高分六号卫星影像,时相为 2024 年 1 月 31 日。遥感影像的处理过程中,由于传感器

和大气传输等因素的干扰,需对原始影像进行辐射定标、大气校正、几何校正、匀色、裁剪、镶嵌等预处理工作,提升影像的准确性和可用性。

2 研究方法

2.1 训练样本制作

基于深度学习的遥感影像样本库包含样本标签和样本影像,训练样本的质量是影响提取精度的关

键因素,在选择样本时,应充分考量各种环境因素和样本特性,以确保样本的多样性、代表性和完整性,从而提高提取结果的准确性。

综合研究区地貌特征,基于 2 米分辨率影像构建均匀分布的油菜样本,样本分布如图 2 所示。

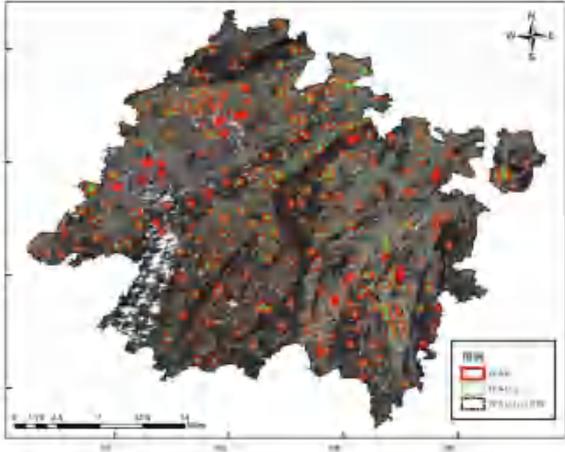


图 2 样本分布图

Fig. 2 Sample distribution diagram

2.2 样本增强

样本增强是在样本数量有限情况下提升模型泛化能力的有效途径之一,为提高模型的泛化能力,通

过丰富样本特征,增加样本数据集、目标地物的复杂性和特征多样性来增强样本^[17]。对原始样本旋转、翻转、缩放、平移、变换色彩等方式生成丰富的训练样本,样本增强效果如图 3 所示。

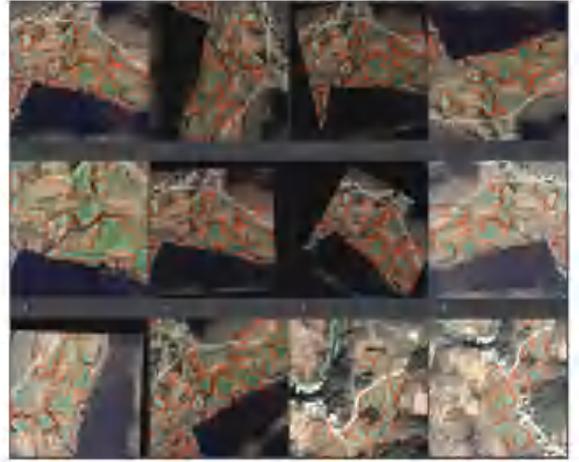


图 3 样本增强效果

Fig. 3 Sample enhancement effect

2.3 模型构建

模型构建框架图如图 4 所示,纵向为建立模型的主要过程,横向是针对具体过程的延展。

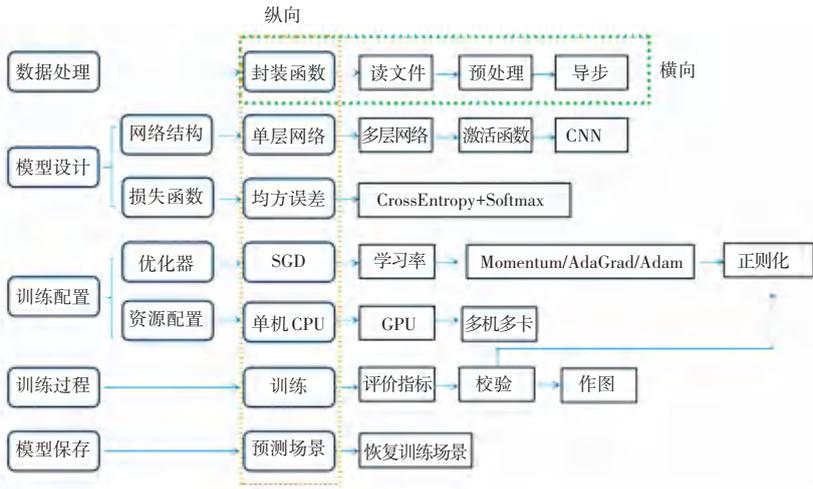


图 4 模型构建框架图

Fig. 4 Model building framework diagram

2.3.1 UNet 网络

Olaf Ronneberger 等^[18]在 2015 年提出一种用于图像分割任务的卷积神经网络架构 UNet 网络,是一种多层次的网络,每一层都包含若干个二维平面,而每一个平面上都有若干个单独神经元,其层次结构依次有卷积层、激活层、池化层、批标准化层、丢弃层以及全连接层^[19]。卷积层通过卷积核与输入图像进行卷积运算,输出一个特征图;池化层降低了特

征图的空间维度,减少参数数量,提高计算效率;全连接层将卷积层和池化层的输出连接起来,形成最终的分类和预测结果。UNet 网络最明显的特点是其 U 形结构,该结构由左侧的编码器和右侧的解码器组成,两者通过跳跃连接(Skip Connections)相连。这种结构使得 UNet 网络在捕捉图像上下文信息的同时,保留图像的细节信息,从而提高分割的精确度,如图 5 所示。

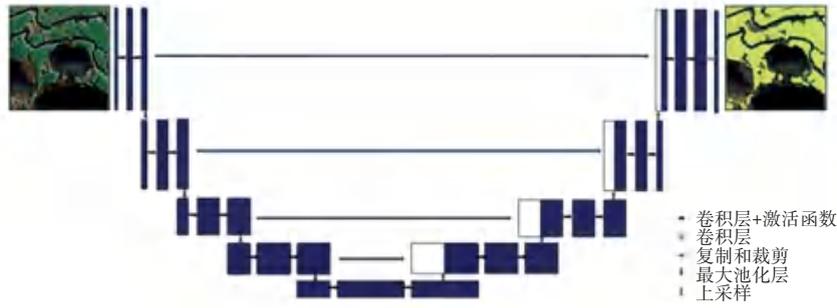


图 5 U-Net 网络架构

Fig. 5 U-Net network architecture

2.3.2 UNet++网络

UNet++网络是对 UNet 网络进行的深化改进和扩展,优化和提升了图像分割的性能。引入多级特征融合和跳跃连接,对 UNet 网络的改进,进一步提高图像分割的准确性和效率,有助于提升模型在图像分割任务中的性能,Unet++网络架构如图 6 所示。

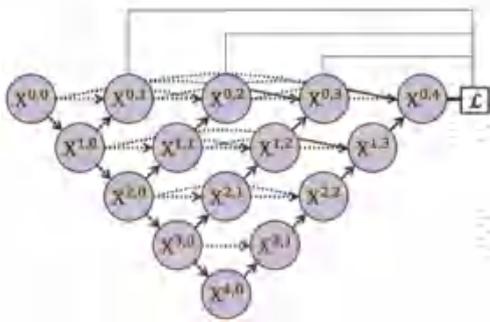


图 6 UNet++网络架构

Fig. 6 UNet++ network architecture

2.3.3 ResNet-101 网络

微软研究院的 He 等^[20]在 2015 年提出 ResNet-101 深度残差网络,属于 ResNet (Residual Network) 系列。ResNet 以残差学习解决深度网络的

梯度消失和爆炸问题,网络堆叠层次更深。ResNet-101 共拥有 101 层,由残差块构成,每个块含卷积、批量归一化和激活函数。在每个残差块中,输入会通过一个或多个卷积层,然后通过一个短路连接与原输入相加,形成残差学习的基础结构。ResNet-101 的这种结构使得网络可以学习输入和输出之间的残差,更容易优化网络。此外,通过添加网络的深度,ResNet-101 能够提取更丰富的特征表示,提高模型在图像识别、目标检测、图像分割等任务上的性能。

2.3.4 Segformer 模型

英伟达团队^[21]提出一种简单而高效的语义分割模型 Segformer,采用 Transformer 架构,Segformer 网络结构图如图 7 所示。通过引入自注意力机制,有效捕捉图像中的全局上下文信息,从而实现高精度的像素级分割。但其模型结构复杂,参数计算量大,在训练过程中需要更多的时间来帮助其优化和迭代。Segformer 模型从 B0 版本扩展至 B5 版本,B0 版本是该系列的基础模型,具有轻量级和高效的特性,B5 版本采用了更复杂的网络结构和更多的参数,比 B0 具有更高的分割精度。

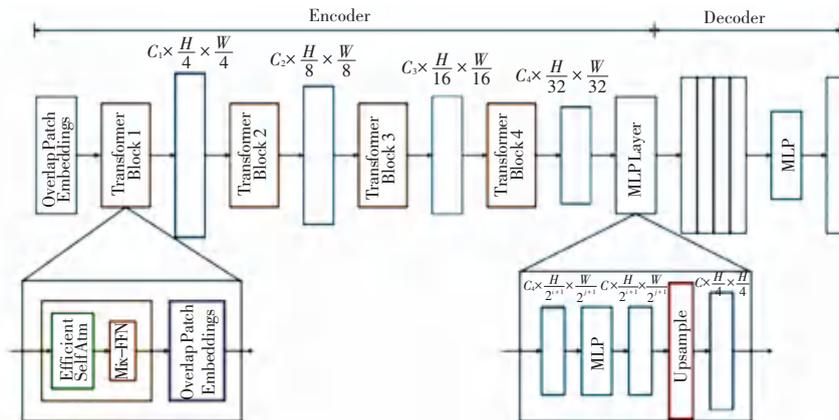


图 7 Segformer 网络结构图

Fig. 7 Segformer network structure diagram

2.4 样本优化

在深度学习模型的训练过程中,样本的质量、数

量、负样本以及影像质量是 4 个至关重要的因素,会直接影响到模型的性能表现。高质量的样本核心在

于其标签的准确性和数据分布的真实反映,能使得模型在学习过程中更加精确地把握学习的目标和数据的本质特征。而一定量的样本数量,可以提供更为丰富的信息,帮助模型更深入地学习数据的特征和规律,从而提高模型的泛化能力。同时,负样本的存在能够帮助模型更好地界定类别边界,防止模型

对非目标类别的错误判断。此外,高质量的影像能够提供更多的细节和特征,帮助模型更准确地识别和理解图像中的信息,从而提高模型的识别准确率。本文通过优化样本质量,添加正、负样本,提高影像质量来优化模型,以期提高模型的性能和准确率,如图 8 所示。

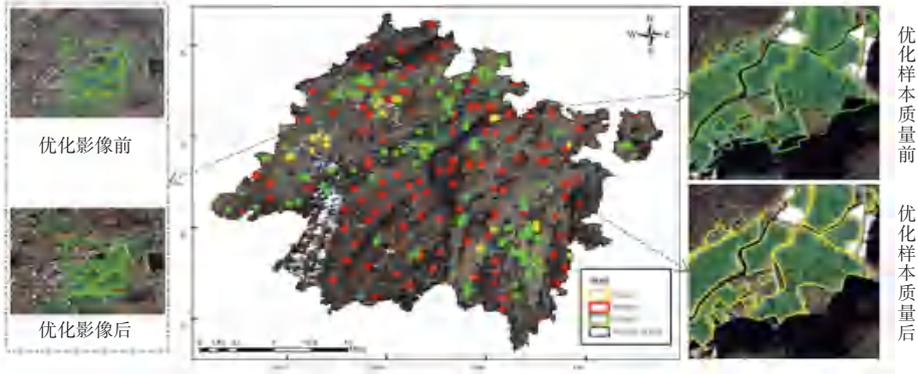


图 8 样本优化

Fig. 8 Sample optimization

2.5 评价指标

本文采用面积精度和套合精度两个指标评估模型的提取效果。面积精度用来评价预测结果与实际结果在面积上的差异,面积精度(AA)表达式:

$$AA = \frac{p_v}{T} \times 100\% \quad (1)$$

其中, p_v 为模型预测图斑面积,即预测值; T 为实地油菜调绘样本图斑面积,即真值。

套合精度用来评价模型预测图斑面积与实地油菜调绘样本图斑面积的重叠率,套合精度(AP)表达式:

$$AP = \frac{N_A}{T} \times 100\% \quad (2)$$

其中, N_A 为预测值与真值的重叠面积,即套合面积; T 为实地油菜调绘样本图斑面积,即真值。

3.1 预训练模型选取

在模型训练过程中,为防止模型过拟合,提高模型泛化能力,获得最优权重参数,需要设置一定规模的训练次数,因此会产生大量预训练模型,合理的选择预训练模型具有重要意义。本文基于 2 米级卫星数据,以 UNet++101 网络为例,分析预训练模型的选取方法,训练指标即时趋势图如图 9 所示。选取不同迭代次数(257、390、495)的 3 个预训练模型,并分别对其进行油菜预测,不同迭代次数预测结果如图 10 所示,可见迭代次数为 390 的预训练模型在油菜提取中其边界较为准确,错提率较低,另外两个预训练模型则出现不同程度的错提和漏提,说明在预训练模型选取时,除应综合考虑模型的精度、召回率及损失率外,还应考虑模型指标的稳定性。

3 试验结果与分析

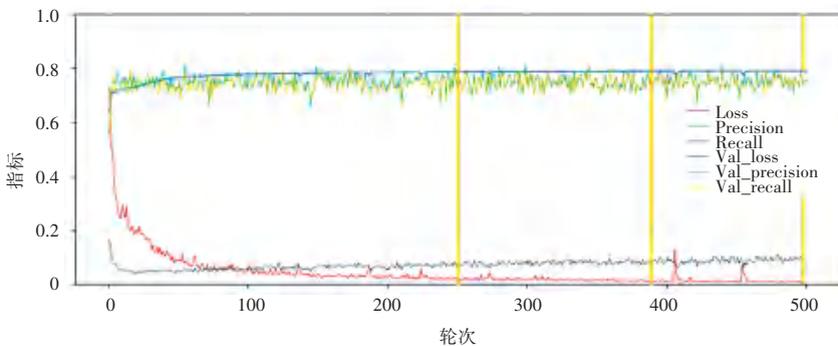


图9 训练指标即时趋势图

Fig. 9 Real-time trend chart of training indicators

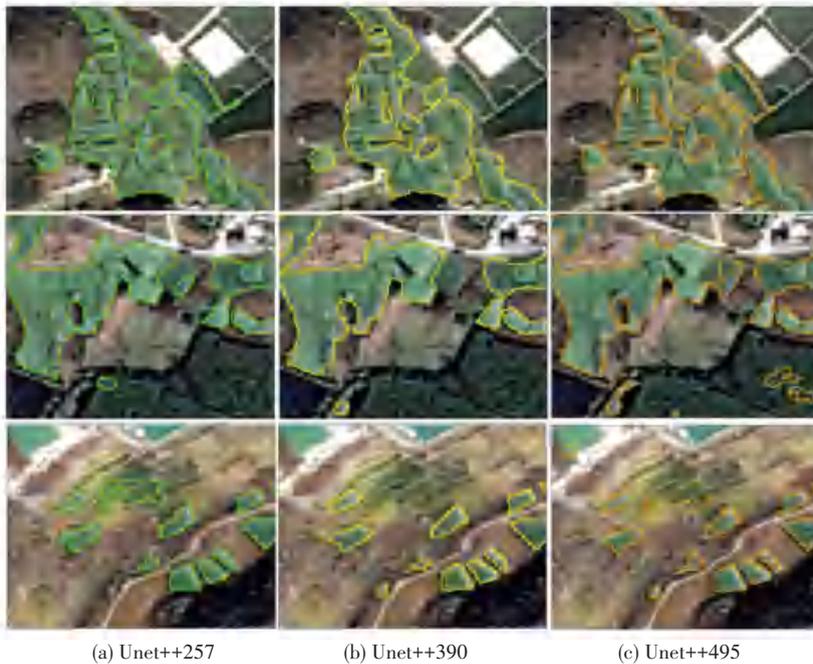


图10 不同迭代次数预测结果对比

Fig. 10 Comparison of prediction results of different iterations

3.2 不同模型精度评估与对比

本文基于2米级卫星数据,利用不同的深度学习模型 SegformerB0、SegformerB5、UNet101、UNet101 来识别油菜,对比提取效果。分别对以上模型进行

多次训练,得到多个不同的预训练模型,并选取对应网络的最优预训练模型对研究区影像进行预测,预测结果见表1。

表1 4个模型预测结果精度表

Table 1 Precision table of prediction results of four models

模型	格网内真值/万亩	格网预测值/万亩	套合面积/万亩	面积精度/%	套合精度/%
SegformerB0	1.975 2	2.052 1	1.658 1	103.89	83.95
SegformerB5		1.965 4	1.616 8	99.50	81.86
UNet101		1.945 3	1.673 2	98.49	84.71
UNet++101(本文模型)		1.981 4	1.747 5	100.31	88.47

由表1可知,4个模型的提取结果中 UNet++101 的面积精度和套合精度较高,分别为 100.31%、88.47%,说明 UNet++101 能更加有效的对研究区油菜进行提取。不同模型在研究区的油菜提取可视化效果如图11所示,UNet、SegformerB0、SegformerB5 3个模型提取的油菜图斑不完整,并错提取水域和其他植被,而 UNet++模型分类精准,提取的油菜图斑轮廓边缘整体与影像地物比较吻合,表现出较高的精确度和稳定性。

3.3 不同分辨率卫星数据精度评估与对比

为进一步验证2米级卫星数据在油菜遥感监测中的可行性,采用同样方法对研究区0.5米和0.8米分辨率影像进行了样本制作和模型训练,并对同一区域对应分辨率影像进行了油菜种植面积预测,其面积精度和套合精度见表2,分辨率为0.5米的油菜预测模型在面积统计精度和图斑套合精度上整体要优于另外两个,而0.8米分辨率的油菜预测模型面积统计精度最低。2米、0.5米和0.8米油菜预测模型对研究区油菜预测可视化结果如图12所示,

可见 3 个油菜预测模型整体预测结果都比较精准, 相差不大, 因 2 米影像的尺度相对较粗, 难以区分同谱异物情形, 在预测过程中存在错提和漏提情况, 因

此在面积统计精度上要高于 0.5 米和 0.8 米油菜预测模型, 但是其套合精度没有其它两个高。

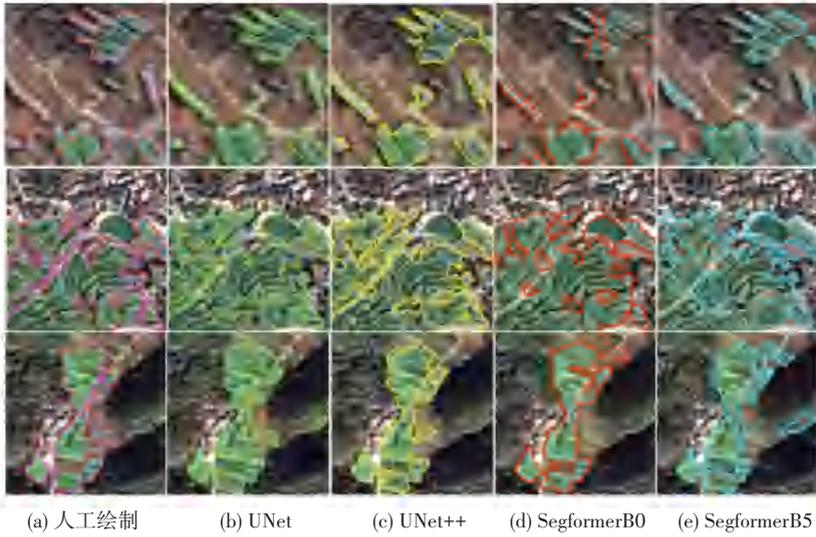


图 11 UNet、UNet++、SegformerB0、SegformerB5 油菜提取结果对比

Fig. 11 UNet, UNet++, SegformerB0, segformerb5 vergleich der ergebnisse der lfrderung

虽然 2 米油菜预测模型整体上没有更高分辨率的油菜预测优, 但是对于一些宏观的面积统计, 其面积统计精度相关较优, 甚至比高分辨率的油菜预测

模型更好, 因此, 利用 2 米分辨率的影像进行油菜遥感监测可行性较高。

表 2 不同分辨率预测结果精度表

Table 2 Accuracy table of prediction results with different resolutions

分辨率/m	格网内真值/万亩	格网预测值/万亩	套合面积/万亩	面积精度/%	套合精度/%
0.5	1.975 2	1.985 5	1.766 4	100.52	89.43
0.8		1.929 0	1.747 5	97.66	88.47
2		1.981 4	1.684 6	100.31	85.29

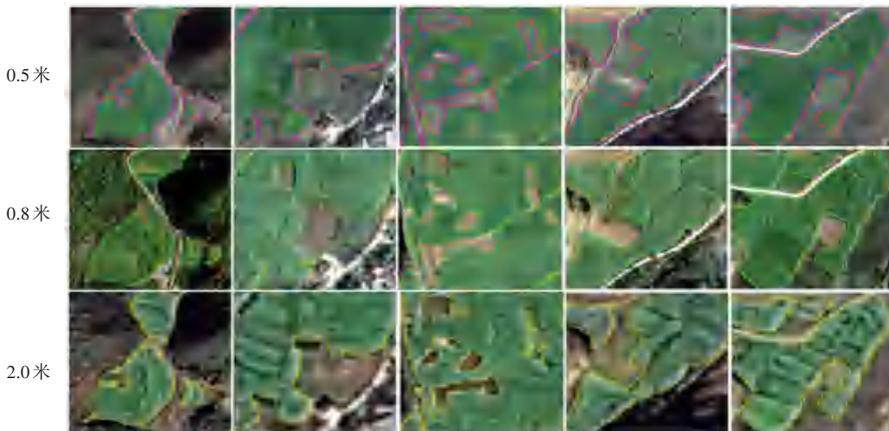


图 12 2 米、0.5 米和 0.8 米油菜预测结果对比

Fig. 12 Comparison of Prediction Results for 2-meter, 0.5-meter, and 0.8-meter rapeseed

3.4 计算效率分析

计算效率涉及到对程序或算法的运行时间、内存占用、资源利用率等方面的度量和比较, 本实验在

GPU 配置为 NVIDIA GeForce RTX4090 电脑上训练, 不同模型在训练和预测过程中的相关计算效率参数见表 3。基于 2 米卫星数据的 4 个模型成果

预测时长差距较小, SegformerB0、SegformerB5 模型训练时间较长, UNet 模型训练时间短, 但提取油菜效果不如 UNet++。基于 0.5 米、0.8 米卫星数据模

型训练和成果预测时间都较长, 综合模型训练时长和预测效果, 基于 2 米卫星数据的 UNet++ 模型性价比更高。

表 3 不同模型训练及预测效率表

Table 3 Table of training and prediction efficiency of different models

分辨率/m	模型名称	GPU 占/GB	GPU 内存利用率/%	CuDa 的最高使用率/%	模型训练总时长/h	单次训练时长/s	成果预测时长/min
2	UNet101	17.1	71.25	98	7	51	83
	UNet++101	19.0	79.17	84	11.45	90	87
	SegformerB0	15.7	65.42	3	18.25	60	89
	SegformerB5	13.7	57.08	1	33.33	120	80
0.8	UNet++101	19.2	80.00	85	45.77	310	150
0.5	UNet++101	19.7	82.08	87	71.81	517	180

4 结束语

本文以贵州省西秀区作为研究区, 结合 2 米级卫星数据, 制作具有区域特色的油菜样本数据集, 在卷积神经网络 UNet++ 框架下, 融合深度残差网络 ResNet-101, 构建了一个适宜于喀斯特高原地区的油菜预测模型。通过相关实验验证, 基于本文模型, 采用 2 米级卫星数据在大范围的油菜面积统计中具有较高的可行性, 但是 2 米级卫星数据在精细的油菜边界提取中, 其性能要低于更高分辨率的油菜预测模型。因此, 对于大范围的油菜精细边界提取除可采用卷积神经网络加高分辨率影像数据方式外, 未来将进一步研究多模态数据结合深度学习方式在作物边界提取中的应用, 以更好地捕获全局上下文信息。

参考文献

[1] 殷艳, 尹亮, 张学昆, 等. 我国油菜产业高质量发展现状和对策[J]. 中国农业科技导报, 2021, 23(8): 1-7.

[2] 刘久锋. 贵州油菜总产有望大幅增长[N]. 农民日报, 2023-06-07(6).

[3] 胡莉, 熊康宁, 肖时珍, 等. 贵州喀斯特地区人地相互作用关系及其调控[J]. 贵州大学学报(自然科学版), 2014, 31(6): 117-121.

[4] 张兴源. 遥感技术在农业生产中的应用[J]. 农业科技与信息, 2023(8): 35-38.

[5] 王鹏飞. 基于无人机遥感影像的小麦生育期识别及倒伏检测系统设计[D]. 咸阳: 西北农林科技大学, 2023.

[6] 卢廷玉. 基于深度学习的遥感影像作物精细分类方法研究[D]. 哈尔滨: 哈尔滨师范大学, 2023.

[7] 王伟. 基于深度学习的高分辨率遥感图像分割方法[J]. 智能计算机与应用, 2023, 13(10): 156-158.

[8] 樊普. 基于深度学习的遥感影像地物提取算法研究[D]. 上海: 华东师范大学, 2023.

[9] 李梓瑜, 王大东, 于晓鹏. 基于 U 型残差网络的遥感图像道路提取方法研究[J]. 智能计算机与应用, 2023, 13(9): 51-58.

[10] 陈佳慧, 路鹏, 罗小玲, 等. 基于 CNN 与 ViT 混合结构的遥感影像地物分类算法[J]. 遥感信息, 2024, 39(3): 121-127.

[11] 何邦科, 朱文泉, 史培军, 等. 复杂地形区植被覆盖度遥感精细估算方法研究——以青藏高原山地区为例[J/OL]. 生态学报, 2024(20): 14. DOI: 10.20103/j.stxb.202403260625

[12] 蒋怡, 董秀春, 王昕, 等. 基于高分六号影像的四川盆地油菜种植调查[J]. 四川农业科技, 2020(1): 68-70.

[13] 李杰, 刘陈立, 汪红, 等. 基于多源遥感数据的罗平油菜种植面积提取方法研究[J]. 西南林业大学学报(自然科学), 2018, 38(4): 133-138.

[14] 曾渝, 王灿辉, 王子一, 等. 基于高分辨率无人机影像的油菜种植区识别[J]. 资源与人居环境, 2023(12): 56-63.

[15] 杨泽宇, 张洪艳, 明金, 等. 深度学习在高分辨率遥感影像冬油菜提取中的应用[J]. 测绘通报, 2020(9): 110-113.

[16] 安顺市西秀区农业农村局. 西秀区 2023 年实际油菜种植补贴资金发放实施方案[EB/OL]. [2023-12-12]. http://www.xixiu.gov.cn/web2023/zwgk/zdlyxxgk/shms/nyncgl/202401/t20240108_83477466.html

[17] 饶杨莉, 张玉金, 周兴霞, 等. 面向深度学习的遥感影像样本库建设技术研究[J]. 测绘与空间地理信息, 2023, 46(4): 38-42.

[18] 苏健民, 杨岚心, 景维鹏. 基于 U-Net 的高分辨率遥感图像语义分割方法[J]. 计算机工程与应用, 2019, 55(7): 207-213.

[19] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.

[20] 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.

[21] 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