

引用格式: Dong Xiuchun, Liu Zhongyou, Jiang Yi, *et al.* Winter Wheat Extraction of WorldView-2 Image based on Semantic Segmentation Method[J]. Remote Sensing Technology and Application, 2022, 37(3): 564-570. [董秀春, 刘忠友, 蒋怡, 等. 基于 WorldView-2 影像和语义分割模型的小麦分类提取[J]. 遥感技术与应用, 2022, 37(3): 564-570.]
DOI: 10.11873/j.issn.1004-0323.2022.3.0564

基于 WorldView-2 影像和语义分割模型的小麦分类提取

董秀春, 刘忠友, 蒋怡, 郭涛, 李宗南

(四川省农业科学院遥感与数字农业研究所, 四川 成都 610066)

摘要: 为使用高分辨率遥感影像和深度学习语义分割模型实现快速准确的小麦种植空间信息提取, 以 WorldView-2 遥感影像为数据源, 制作尺度分别为 128×128 、 256×256 、 512×512 的样本数据集, 对 U-net 和 DeepLabv3+ 语义分割模型的参数进行训练, 建立小麦遥感分类模型; 通过与极大似然和随机森林方法比较, 检验深度学习分类效果。结果显示: ① 不同尺度样本训练得到的模型总体精度、Kappa 系数分别在 94% 和 0.82 以上, 模型精度稳定, 样本尺度大小对小麦分类提取模型影响较小; ② 深度学习方法的分类总精度和 Kappa 系数分别在 94% 和 0.89 以上, 极大似然和随机森林则在 92% 和 0.85 以下, 表明该研究建立的小麦遥感分类模型优于传统分类方法。研究结果可为高分辨率遥感影像作物种植信息的深度学习提取提供参考。

关键词: 高分辨率影像; U-net; DeepLabv3+; 小麦; 信息提取

中图分类号: S127; TP75 **文献标志码:** A **文章编号:** 1004-0323(2022)03-0564-07

1 引言

高分辨率光学遥感影像能清晰反映地物的几何结构和纹理特征, 可准确获取地块边界和作物种植、倒伏面积等信息, 普遍应用于地面样方调查^[1]、作物遥感精细分类^[2]、农业灾害评估^[3]等农情遥感监测业务。在高分辨率遥感影像地物识别与分类过程中, 受地物空间异质性大、“同物异谱”等影响, 导致其基于最大似然监督分类方法准确性降低、基于面向对象的分类方法存在尺度问题^[4]。目前, 机器学习是处理高分辨率影像分类提取的主要方法。研究人员采用 SVM^[5]、随机森林^[6]等为代表的浅层机器学习方法进行分类提取, 在小范围获得了较高的分类提取精度, 但由于模型的网络结构和泛化能力有限, 不能处理大量、复杂特征样本, 且自动化程

度不高^[7]; 通过建立基于深度学习的语义分割模型, 如 SegNet^[8-9]、DeepLabv3+^[10-12]、U-net^[13-15]等, 完成 WorldView-2、GF-2、BJ-2 等多种高分辨率遥感影像的分类提取任务, 实现了农村建筑物、覆盖地膜田块、积雪、甘蔗、水体、设施大棚和果园等地物的信息提取, 并取得较传统分类方法和浅层机器学习方法更高的精度。

深度学习通过构建多层隐含神经网络模型, 从大量、复杂特征样本数据集中实现特征的自动提取和自动分类, 在高分辨率遥感影像分类提取中表现出显著优势^[16-19]。受限于计算机软硬件处理能力, 参与训练的样本数据需要切割, 尺度过大则会消耗大量计算资源; 过小则会丢失其全局信息, 影响分类准确性, 因此样本尺度是决定模型训练的

收稿日期: 2021-01-22; 修订日期: 2022-03-15

基金项目: 四川省科技计划项目“农业大数据资产管理及智能分析应用系统”(2021YFG0028), 成都市重点研发支撑计划技术创新研发项目“互联网+机器学习下的农情遥感监测方法与大数据平台”(2019-YF05-01368-SN)。

作者简介: 董秀春(1987—), 女, 四川南部人, 硕士, 助理研究员, 主要从事农业遥感方面的研究。E-mail: 642721838@qq.com

通讯作者: 李宗南(1983—), 男, 广西武鸣人, 博士, 副研究员, 主要从事农业遥感和农业土地利用研究。E-mail: li_zongnan@foxmail.com

效率和最终的分类效果的关键^[20-21]。已有研究表明,采用WorldView-2影像提取几何形状规则的农村建筑物,样本尺度为 128×128 的模型分类精度能够达到最高^[8];使用SAR影像和卷积神经网络模型进行海冰分类,训练样本尺度为 16×16 时模型分类性能最佳^[22];针对作物分类提取的最佳尺度选取研究未见相关报道。为建立基于高分辨率遥感影像的小麦分类模型并准确提取空间信息,实现作物种植精细调查,研究以WorldView-2影像为数据源、采用DeepLabv3+和U-net语义分割模型,通过设置不同尺度的样本进行模型优化训练、建立小麦分类模型、提取小麦种植信息;综合对比分析不同尺度样本下模型的精度、效率等指标,以期基于高

分辨率遥感影像的深度学习方法农情信息提取高效应用提供参考。

2 研究区和数据

2.1 研究区概况

研究区位于成都市西南部,涉及邛崃市、大邑县、新津区等部分地区,影像覆盖区域为 $6\text{ km}\times 19\text{ km}$,见图1。该区域属亚热带湿润气候,四季分明,平均气温 $17.8\text{ }^{\circ}\text{C}$,年均降雨量约 $1\,300\text{ mm}$;区域内地势平坦,土壤肥沃,灌溉条件良好,适合多种作物生长,主要作物有小麦、油菜、蔬菜、猕猴桃、葡萄、柑橘等,其余地物包括设施大棚、坑塘、河流、道路和建筑物等。

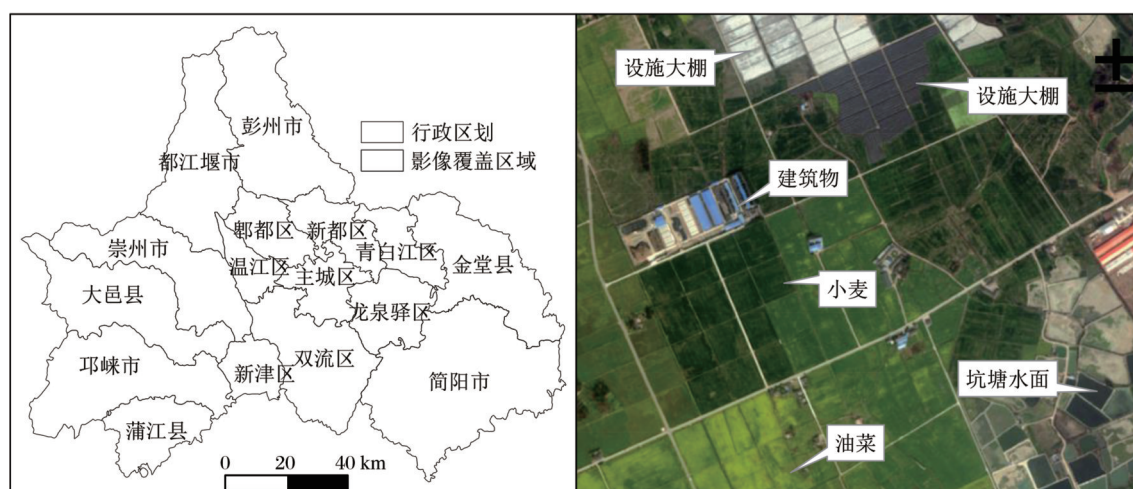


图1 影像覆盖区域及主要解译标志

Fig.1 The area of remote sensing image coverage and interpretation signs of typical features

2.2 数据来源

研究使用的数据包括高分辨率遥感影像数据和地面调查数据。其中,影像数据为通过订购方式获取的2018年2月28日过境的Worldview-2卫星影像,该数据包括全色和多光谱影像,具体光谱信息见表1。地面调查数据于2018年1月中旬在研究区获取包括地物解译标志、调查样方内土地利用现状等数据,为影像地物标注和分类精度验证提供数据支持。

3 研究方法

3.1 训练样本制作

首先在ENVI 5.3中使用格网间距为 30 m 的DEM数据分别对Worldview-2全色和多光谱影像进行更高精度的正射校正;然后进行数据融合,生成分辨率为 0.5 m 的8波段多光谱影像数据。结合

表1 WorldView-2数据光谱信息

Table 1 The spectral information of WorldView-2

波段名	空间分辨率/m	半值波宽/nm	中心波长/nm
全色	0.5	336.9	632.2
海岸蓝	2.0	51.8	427.3
蓝色	2.0	60.8	477.9
绿色	2.0	69.8	546.2
黄色	2.0	38.5	607.8
红色	2.0	59.3	658.8
红边	2.0	39.8	723.7
近红外1	2.0	117.8	832.5
近红外2	2.0	92.5	908.0

地面调查采集的解译标志点,对比多种波段组合效果,选取近红外2(R)、红边(G)和红光(B)波段进行假彩色合成突出小麦显示效果,人工目视解译勾绘出小麦种植区域地块边界线,生成标签数据。为提高模型训练速度,提取近红外2、红边和红光3个波

段数据用于影像样本数据生产。样本尺度采用常用的 128×128 、 256×256 和 512×512 等 3 种尺度, 分别用 $64 \text{ m} \times 64 \text{ m}$ 、 $128 \text{ m} \times 128 \text{ m}$ 和 $256 \text{ m} \times 256 \text{ m}$ 的规则网格对影像数据和标签数据进行裁减, 生成对应的 3 组样本训练数据集, 即 7 680 个样本尺度大小为 128×128 、1 920 个样本尺度大小为 256×256 和 480 个样本尺度为 512×512 的影像—标签对。将每组样本数据按照 60%、20% 和 20% 的比例划分为训练、验证和测试数据, 参与模型训练、精度评价和模型测试。

3.2 语义分割模型

U-net 和 DeepLabv3+ 模型均是基于全卷积神经网络(FCN)模型的改进和发展。U-net^[23] 模型最早用于医学图像分割, 是标准的编码—解码网络结构, 编码器通过连续的卷积、下采样逐层提取影像特征; 解码器主要通过上采样操作逐渐增加特征图分辨率, 并以拼接方式将解码器和编码器中相同分辨率的特征图进行特征融合, 逐步还原影像的细节信息和位置信息, 以实现像素的语义标注; U-net 模型结构清晰、处理速度较快, 在小样本数据集上能取得较好训练效果^[24]。

DeepLabv3+^[25] 模型是 DeepLab 系列最新的网络结构, 在特征提取时通过采用空洞卷积控制感受野, 集成空间金字塔池化(ASPP)模块提取多尺度特征信息; 在 DeepLabv3 基础上添加解码模块细化对象分割结果; 使用 Xception 模型作为骨干网络来处理分割任务, 并在 ASPP 模块和解码器模块上应用深度可分离卷积, 以提高模型精度和速度; DeepLabv3+ 在处理细节丰富的图像方面较强优势^[19]。

3.3 模型训练

模型训练环境为 Ubuntu 18.04, 采用 GPU 为 NVIDIA Quadro RTX 4000, 内存 8 G, CUDA 版本为 11.0; 使用基于开源深度学习框架百度 Paddle-Paddle 平台下的图像分割套件 PaddleSeg, 搭建 U-net 和 DeepLabv3+ 小麦种植信息提取模型; 分别加入 3 组样本数据集进行 U-net 和 DeepLabv3+ 模型训练和保存。在训练过程中, 主要参数设置包括: 网络优化函数为 adam, 学习率下降方法为 poly, DeepLabv3+ 的模型骨架网络选取 Xception_65, 初始学习率为 0.001, 迭代次数为 300, 训练批数随尺度的升高分别为 50、12 和 4, 数据增强方式为按固定尺度(512×512)进行图像缩放, 训练的损失函数为 Softmax。

3.4 模型评估和预测

根据建立的 U-net、DeepLabv3+ 模型, 通过不同尺度的验证数据进行精度评估, 综合对比分析不同尺度样本下各模型的总精度、Kappa 系数、交并比 (IOU)、耗时等指标, 为小麦种植信息提取模型建立选择最优的样本尺度; 对最佳样本尺度的测试数据进行预测, 随机选取 12 个测试图片的预测分割结果, 结合人工标注计算小麦分类的混淆矩阵 (包括错分误差、漏分误差、总精度、Kappa 系数), 并以极大似然监督分类和随机森林分类结果为参照, 综合评估建立的深度学习语义分割模型的分类效果。

4 结果与分析

4.1 不同尺度样本训练的模型精度

统计 U-net 和 DeepLabv3+ 模型在不同尺度的验证数据下模型精度评估结果, 其总体精度、Kappa 系数、IOU 及耗时等指标见表 2。根据表 2, U-net 和 DeepLabv3+ 模型精度评估差别不大, 模型总体精度均在 94% 以上, Kappa 系数和 IOU 分别均在 0.82 和 0.84 以上, 分类结果较好, 模型精度稳定, 表明语义分割模型用于高分辨率遥感影像的小麦种植信息提取具有较好的分类效果。对比 U-net 和 DeepLabv3+ 模型的总体精度、Kappa 系数和 IOU 等指标, U-net 模型的整体精度略高于 DeepLabv3+, 主要表现在 U-net 的总体精度、Kappa 系数和 IOU 的取值范围分别在 94%~96%、0.83~0.87 和 0.85~0.88 之间, 而 DeepLabv3+ 则为 94%~95%、0.81~0.83 和 0.83~0.85 之间; U-net 模型训练耗时整体少于 DeepLabv3+。由此表明, 较 DeepLabv3+ 模型, U-net 模型在基于 Worldveiw-2 影像的深度学习小麦分类提取中计算速度快、适应性强。

表 2 U-net 和 DeepLabv3+ 模型在不同尺度样本下的评价指标对比

Table 2 Comparison of evaluation indicators between U-net and DeepLabv3+ under different scale

模型	样本 尺度	总精 度/%	Kappa	IOU	耗时 /min
U-net	128×128	96.30	0.871 5	0.882 2	148
	256×256	95.47	0.852 9	0.866 7	129
	512×512	94.68	0.835 2	0.851 4	144
DeepLabv3+	128×128	95.15	0.833 1	0.850 5	169
	256×256	94.65	0.817 9	0.838 4	163
	512×512	94.62	0.831 5	0.848 4	162

从不同尺度样本训练的模型精度来看,U-net 和 DeepLabv3+ 模型的精度评价指标整体变化均不大,表明样本尺度对基于语义分割的小麦分类模型训练结果影响较小。不同模型之间对样本尺度变化的灵敏度略有差异,主要表现为:随着样本尺度增加,U-net 模型训练后的精度指标变化特征明显,略有降低的趋势,耗时变化较小;而 DeepLabv3+ 的精度评价指标没有明显变化特征,3 组样本参与模型训练的耗时相当。综合精度评价指标及模型训练耗时,选取 U-net 语义分割模型、裁减尺度为 256×256 的样本建立基于 Worldview-2 影像的小麦分类模型并准确提取空间信息具有更高的精度和效率。

4.2 基于深度学习分类方法的小麦空间信息提取

根据样本尺度为 256×256 训练的 U-net 和 DeepLabv3+ 模型预测结果,计算混淆矩阵,对比极大似然和随机森林分类,统计结果见表 3。

表 3 不同分类方法小麦提取精度

Table 3 Precision analysis of winter wheat extraction of different classification methods

分类方法	错分误差	漏分误差	总精度/%	Kappa
U-net	5.30	3.12	95.63	0.912 4
DeepLabv3+	5.69	4.35	94.81	0.896 2
随机森林	9.56	4.36	92.59	0.851 5
极大似然	10.88	4.75	91.61	0.831 9

基于深度学习语义分割模型的 Worldview-2 影像小麦种植信息提取精度最高,表现出较好的分类结果,由此说明建立的小麦种植信息提取模型适应性良好。从总精度和 Kappa 系数来看,U-net 和 DeepLabv3+ 模型分别在 94% 和 0.89 以上,明显高于基于传统的极大似然和基于浅层机器学习的随机森林,尤其是 Kappa 系数,差异最为明显。对比错分、漏分误差等指标,U-net 和 DeepLabv3+ 模型整体最低,主要表现为两者的错分误差明显低于极大似然和随机森林,也是改善分类效果、提升分类精度的主要原因,进一步说明深度学习语义分割模型在高分辨率遥感影像作物种植信息提取中较传统方法有较大优势。对比深度学习语义分割模型分类结果,U-net 模型的错分、漏分误差略低于 DeepLabv3+,在处理 Worldview-2 影像的小麦提取中性能略优于 DeepLabv3+。

分别选取 U-net 和 DeepLabv3+ 模型小麦提取结果的典型区域进行局部放大显示,以极大似然和

随机森林分类结果为参照,见图 2。基于深度学习语义分割模型的小麦提取效果明显优于随机森林和极大似然,主要表现在:较传统分类方法,语义分割模型的小麦提取结果中几乎不存在部分像元接近小麦的地块边界线、林地等地物;图斑噪声现象明显减少,图斑完整性增强,整体效果得到改善;分类结果无需过多的分类后处理过程,影像处理的自动化程度有较大提升。对比 U-net 和 DeepLabv3+ 模型的小麦提取效果,二者之间差异不明显,各有优缺点。二者均存在少量漏分现象,如区域一和区域二的红色矩形框内,部分长势较差的小麦均未被 DeepLabv3+ 和 U-net 提取;均存在不同程度的错分情况,如区域三红色矩形框区域内部分其他作物被错分为小麦,但 DeepLabv3+ 较 U-net 错分更为明显;在局部区域细节把握方面,DeepLabv3+ 略显优势,如图 2 区域四的红色矩形框内,该区域的田坎分割效果较 U-net 更为清晰。

5 讨 论

深度学习语义分割模型在处理复杂场景高分辨率影像分类方面较传统分类方法具有绝对优势。研究采用 U-net 和 DeepLabv3+ 语义分割模型及不同尺度的样本数据,综合模型的训练精度和效率,建立了基于 WorldView-2 影像的小麦分类提取模型,为高分辨率遥感影像的深度学习种植信息提取提供参考。在分析样本尺度对模型精度的影响时,研究仅采用 3 种常用尺度的样本数据,得出初步的定性分析结果,进一步定量分析样本尺度对不同模型、不同影像的精度影响,可生产不同尺度、步长的样本数据集,并对影像数据各波段反射率加入指定范围的噪声进行样本扩增,以提高模型的泛化能力,得出最佳尺度选择。

随着高分辨率遥感影像的不断丰富及现代农业种植的信息需求增加,未来需加强地面调查,获取典型地物及作物解译标志等,建立本地化的作物样本数据集,以解决深度学习作物分类提取样本受限的问题,促进深度学习在作物遥感监测中的应用研究。同时,利用高空间分辨率遥感影像丰富的几何结构、纹理特征,采用擅长特征学习的深度学习方法进行农田地块提取;然后以地块为基本单元,应用多源高分辨率遥感数据,进一步实现主要农作物面向地块尺度的精细分类提取^[28-30],以期为作物种植信息精准普查、农业生产精细化管理以及区域

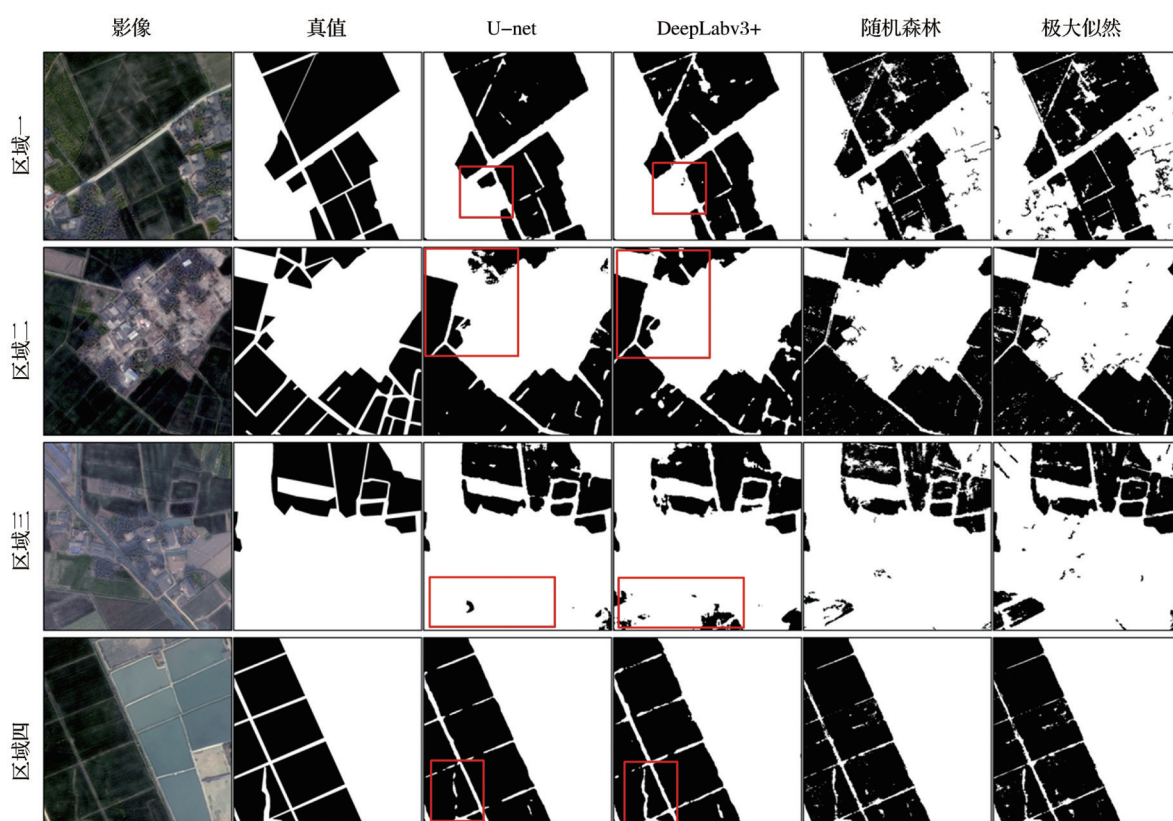


图 2 研究区 4 个典型区域小麦提取结果对比

Fig.2 Four typical images subsets with their classification results under different methods

种植业结构优化等提供信息服务。

6 结 论

本文采用开源深度学习语义分割模型 U-net 和 DeepLabv3+, 分别加入尺度为 128×128 、 256×256 、 512×512 的 Worldview-2 影像样本训练数据集进行模型训练和预测, 并以传统的极大似然和浅层机器学习随机森林为参照, 得出如下结论: ①不同尺度样本下模型训练的精度评价为分类总体精度和 Kappa 系数在 94%~96% 之间和 0.82~0.87 之间, 精度评估差别不大, 表明作物分类模型精度稳定, 样本尺度大小对语义分割模型影响较小。②使用语义分割模型进行 WorldView-2 影像小麦种植信息提取时, 综合模型精度评价指标及耗时, 模型为 U-net、样本尺度为 256×256 为最优组合。③深度学习方法的分类体总精度和 Kappa 系数均在 94% 和 0.89 以上, 明显优于极大似然和随机森林, 该研究建立的小麦遥感分类模型优于传统分类方法。

参考文献 (references):

- [1] Liu Jia, Wang Limin, Teng Fei, *et al.* Crop area ground sample survey using Google Earth image-aided[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(24): 157-162.[刘佳, 王利民, 滕飞, 等. Google_Earth 影像辅助的农作物面积地面样方调查[J]. 农业工程学报, 2015, 31(24): 157-162.]
- [2] Zhang Peng, Hu Shougeng. Fine crop classification by remote sensing in complex planting areas based on field parcel[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(20): 125-134.[张鹏, 胡守庚. 地块尺度的复杂种植区作物遥感精细分类[J]. 农业工程学报, 2019, 35(20): 125-134.]
- [3] Li Zongnan, Chen zhongxin, Ren Guoye, *et al.* Estimation of maize lodging area based on Worldview-2 image[J]. Transactions of the Chinese Society of Agricultural Engineering, 2016, 32(2): 1-5.[李宗南, 陈仲新, 任国业, 等. 基于 Worldview-2 影像的玉米倒伏面积估算[J]. 农业工程学报, 2016, 32(2): 1-5.]
- [4] Li Deren, Tong Qingxi, Li Rongxin, *et al.* Current issues in high-resolution earth observation technology[J]. China Science: Earth Sciences, 2012, 2012, 42(6): 805-813.[李德仁, 童庆禧, 李荣兴, 等. 高分辨率对地观测的若干前沿科学问题[J]. 中国科学: 地球科学, 2012, 42(6): 805-813.]
- [5] Luo Huan, Li Weiguo, Jing Yuanshu, *et al.* Remote sensing extraction of winter wheat planting area based on SVM[J]. Journal of Triticeae Crop, 2019, 39(4): 455-46.[罗桓, 李卫

- 国,景元书,等.基于SVM的县域冬小麦种植面积遥感提取[J].麦类作物学报,2019,39(4):455-462.]
- [6] Wang Limin, Liu Jia, Yang Lingbo, *et al.* Application of random forest method in maize-soybean accurate identification[J]. Acta Agronomica Sinica, 2018, 44(4): 101-112.[王利民,刘佳,杨玲波,等.随机森林方法在玉米-大豆精细识别中的应用[J].作物学报,2018,44(4):101-112.]
- [7] Zhang Bing. Remote sensed big data era and intelligent information extraction[J]. Geomatics and Information Science of Wuhan University, 2018, 43(12): 108-118.[张兵.遥感大数据时代与智能信息提取[J].武汉大学学报(信息科学版),2018,43(12):108-118.]
- [8] Yang Jianyu, Zhou Zhenxu, Du Zhenrong, *et al.* Rural construction land extraction from high spatial resolution remote sensing image based on SegNet semantic segmentation model[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(5): 259-266.[杨建宇,周振旭,杜贞容,等.基于SegNet语义模型的高分辨率遥感影像农村建设用地提取[J].农业工程学报,2019,35(5):259-266.]
- [9] Yang Q C, Liu M, Zhang Z T, *et al.* Mapping plastic mulched farmland for high resolution images of unmanned aerial vehicle using deep semantic segmentation[J]. Remote Sensing, 2019, 11(17): 2008. DOI:10.3390/rs11172008.
- [10] Guo X, Chen Y, Liu X, *et al.* Extraction of snow cover from high-resolution remote sensing imagery using deep learning on a small dataset[J]. Remote Sensing Letters, 2020, 11(1): 66-75. DOI:10.1080/2150704X.2019.1686548.
- [11] Gou Jiesong, Jiang Yi, Li Zongnan, *et al.* Aquaculture water body information extraction in the Chengdu plain based on Deeplabv3+ model[J]. Journal of Agriculture Mechanization, 2021,42(3): 105-112.[苟杰松,蒋怡,李宗南,等.基于Deeplabv3+模型的成都平原水产养殖水体信息提取[J].中国农机化学报,2021,42(3):105-112.]
- [12] Osco L P, Nogueira K, Marques ramos AP, *et al.* Semantic segmentation of citrus-orchard using deep neural networks and multispectral UAV-based imagery[J]. Precision Agriculture, 2021,22(4):1171-1188.DOI:10.1007/s11119-020-09777-5.
- [13] Dong Xiuchun, Jiang Yi, Wang Si, *et al.* Extraction of sugarcane from Google Earth image based on the U-Net model[J]. China Agricultural Informatics, 2019, 31(6): 29-34.[董秀春,蒋怡,王思,等.基于U-Net的甘蔗提取方法[J].中国农业信息,2019,31(6):29-34.]
- [14] He Hongshu, Huang Xiaoxia, Li Hongga, *et al.* Water body extraction of high resolution remote sensing image based on improved U-Net Network[J]. Journal of Geo-information Science, 2020, 22(10): 2010-2022.[何红术,黄晓霞,李红杏,等.基于改进U-Net网络的高分遥感影像水体提取[J].地球信息科学学报,2020,22(10):2010-2022.]
- [15] Zheng Lei, He Zhimeng, Ding Haiyong. Research on the sparse plastic shed extraction from high resolution images using Envinet 5 Deep Learning Method[J]. Remote Sensing Technology and Application,2021,36(4):908-915.[郑磊,何直蒙,丁海勇.基于Envinet 5的高分辨率遥感影像稀疏塑料大棚提取研究[J].遥感技术与应用,2021,36(4):908-915.]
- [16] Chen Qian, Zheng Lijuan, Li Xiaojuan, *et al.* Water body extraction from high-resolution satellite remote sensing images based on deep learning[J]. Geography and Geo-Information Science, 2019, 35(4): 43-49.[陈前,郑利娟,李小姐,等.基于深度学习的高分遥感影像水体提取模型研究[J].地理与地理信息科学,2019,35(4):43-49.]
- [17] Liu Dawei, Han Ling, Han Xiaoyon. High spatial resolution remote sensing image classification based on deep learning[J]. Acta Optica Sinica, 2016, 36(4): 306-314.[刘大伟,韩玲,韩晓勇.基于深度学习的高分辨率遥感影像分类研究[J].光学学报,2016,36(4):306-314.]
- [18] Yang Rui, Qi Yuan, Su Yang. U-Net Neural networks and its application in high resolution satellite image classification[J]. Remote Sensing Technology and Application, 2020, 35(4): 767-774.[杨瑞,祁元,苏阳.深度学习U-Net方法及其在高分辨卫星影像分类中的应用[J].遥感技术与应用,2020,35(4):767-774.]
- [19] Zhang C M, Gao S, Yang X X, *et al.* Convolutional neural network-based remote sensing images segmentation method for extracting winter wheat spatial distribution[J]. Applied Sciences-Basel, 2018, 10(8): 1981. DOI:10.3390/app8101981.
- [20] Du P, Samat A, Waske B, *et al.* Random forest and rotation forest for fully polarized sar image classification using polarimetric and spatial features[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 105: 38-53. DOI: 10.1016/j.isprsjprs.2015.03.002.
- [21] Tang Wenli. Multi-scale semantic segmentation of remote sensing image based on deep residual network[D]. Wuhan: Wuhan University, 2018.[唐文莉.基于深度残差网络的多尺度遥感影像语义分割研究[D].武汉:武汉大学,2018.]
- [22] Huang Dongmei, Li Minghui, Song Wei, *et al.* Performance of convolutional neural network and deep belief network in sea ice-water classification using SAR imagery[J]. Journal of Image and Graphics, 2018, 23(11): 1720-1732.[黄冬梅,李明慧,宋巍,等.卷积神经网络和深度置信网络在SAR影像冰水分类的性能评估[J].中国图象图形学报,2018,23(11):1720-1732.]
- [23] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]// International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2015.
- [24] Su Jianmin, Yang Lanxin, Jing Weipeng. U-Net based semantic segmentation method for high resolution remote sensing image[J]. Computer Engineering and Applications, 2019, 55(7): 207-213.[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.]
- [25] Chen L C, Zhu Y, Papandreou G. Encoder-Decoder with atrous separable convolution for semantic image segmentation [C]// Computer Vision-ECCV 2018, Springer, Cham, 2018:

- 833-851.
- [26] Yang Yingpin, Wu Zhifeng, Luo Jiancheng, *et al.* Parcel-based crop distribution extraction using the spatiotemporal collaboration of remote sensing data[J]. Transactions of the Chinese Society of Agricultural Engineering 2021, 37(7): 166-174.[杨颖频,吴志峰,骆剑承,等.时空协同的地块尺度作物分布遥感提取[J].农业工程学报,2021,37(7):166-174.]
- [27] Yang Shuqin, Song Zhishuang, Yin Hanping, *et al.* Crop classification method of UVA multispectral remote sensing based on deep semantic segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 1-13. [杨蜀秦,宋志双,尹瀚平,等.基于深度语义分割的无人机多光谱遥感作物分类方法[J].农业机械学报,2021,52(3):1-13.]
- [28] Wu Zhifeng, Luo Jiancheng, Sun Yingwei, *et al.* Research on precision agricultural based on the spatial-temporal remote sensing collaboration[J]. Journal of Geo-information Science, 2020, 22(4): 731-742.[吴志峰,骆剑承,孙营伟,等.时空协同的精准农业遥感研究[J].地球信息科学学报,2020,22(4):731-742.]

Winter Wheat Extraction of WorldView-2 Image based on Semantic Segmentation Method

Dong Xiuchun, Liu Zhongyou, Jiang Yi, Guo Tao, Li Zongnan

(Institute of Remote Sensing and Digital Agriculture, Sichuan Academy of Agricultural Sciences,
Chengdu 610066, China)

Abstract: In order to realize fast and accurate extraction of winter wheat planting spatial information by using high-resolution remote sensing image and deep learning semantic segmentation model, worldView-2 remote sensing image was used as the data source to produce the sample data sets with the scales of 128×128 , 256×256 and 512×512 , which trained the parameters of U-net and DeepLabv3+ semantic segmentation model to establish remote sensing classification model of winter wheat. The classification effects of deep learning was tested by comparing with maximum likelihood and random forest methods. The results showed that: (1) the overall accuracy and Kappa coefficient of the models obtained by training samples of different scales were more than 94% and 0.82, and the model accuracy was stable, which indicated that the sample sizes have little influence on the semantic segmentation model of winter wheat classification. (2) The overall classification accuracy and Kappa coefficient of the deep learning methods were above 94% and 0.89, while the maximum likelihood and random forest were below 92% and 0.85, respectively. This results suggested that the remote sensing classification model of winter wheat established in this study was superior to the traditional classification methods. The results can provide the references for the deep learning methods of crop planting information extraction with high resolution remote sensing image.

Key words: High-resolution remote sensing images; U-net; DeepLabv3+; Winter wheat; Information extraction