

## 地块尺度的山区耕地精准提取方法

周楠<sup>1,2</sup>, 杨鹏<sup>1</sup>, 魏春山<sup>1</sup>, 沈占锋<sup>1,2\*</sup>, 余娟娟<sup>3</sup>, 马晓宇<sup>4</sup>, 骆剑承<sup>1,2</sup>

(1. 中国科学院空天信息创新研究院, 北京 100101; 2. 中国科学院大学, 北京 100049;  
3. 河海大学地球科学与工程学院, 南京 211100; 4. 河北工程大学地球科学与工程学院, 邯郸 056000)

**摘要:** 山地丘陵区域耕地资源稀缺, 耕地碎片化现象严重, 耕地地块细小狭窄且结构复杂, 导致了地块级别的耕地信息难以快速、精准获取, 阻碍了基于高分辨率遥感影像的精准数字农业服务在山地丘陵地区的应用。现有基于边缘检测/语义分割的耕地提取方法忽略了地块的结构化特征, 对于狭长地块提取效果不佳, 存在边界模糊问题。针对上述问题, 该研究以西南山区湖南省邵东县为研究区, 提出一种面向地块尺度的山区耕地遥感影像高精度提取方法。该研究模型主要有以下特征: 1) 将耕地边缘作为独立于耕地地块外的新类别, 使得语义分割能够更好地区分耕地地块边缘和内部区域; 2) 级联语义分割网络和边缘检测网络, 实现耕地边缘线特征和面特征的融合, 使耕地边缘特征强化, 提高耕地地块边缘检测精度; 3) 针对高分影像中耕地边缘像素远少于耕地内部像素问题, 借助聚焦训练方法, 使模型在训练过程中更加关注边缘像素, 提高边缘检测精度。试验结果证明, 该研究提出的方法在测试集上分类准确率和交并比分别为 92.91% 和 82.84%, 相比基准方法分别提升 4.28 个百分点和 8.01 个百分点。该研究所提取的耕地地块相比于现有方法更符合耕地的实际分布形态, 为地块尺度的耕地信息精准提取提供了实用化方法。

**关键词:** 遥感; 高分辨率影像; 山区; 语义分割; 边缘检测; 耕地地块

doi: 10.11975/j.issn.1002-6819.2021.19.030

中图分类号: TP79

文献标志码: A

文章编号: 1002-6819(2021)-19-0260-07

周楠, 杨鹏, 魏春山, 等. 地块尺度的山区耕地精准提取方法[J]. 农业工程学报, 2021, 37(19): 260-266.

doi: 10.11975/j.issn.1002-6819.2021.19.030 <http://www.tcsae.org>

Zhou Nan, Yang Peng, Wei Chunshan, et al. Accurate extraction method for cropland in mountainous areas based on field parcel[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2021, 37(19): 260-266. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2021.19.030 <http://www.tcsae.org>

## 0 引言

数字农业是在整个生长季节监测耕地的重要手段。及时准确的农业信息是国家制定农业政策的重要依据, 对保证粮食安全有着重要的意义<sup>[1-3]</sup>。早期的耕地边界信息主要是通过人工绘制的方式进行采集, 虽然数据较为准确, 但需要耗费大量的人力和物力, 阻碍了精准数字农业的发展。随着科学技术的发展, 越来越多的遥感对地观测技术被用于种植面积统计、作物病虫害监测以及作物产量预估<sup>[4]</sup>。随着卫星遥感影像的空间分辨率不断提高, 其所能呈现的地物视觉特征更加精细, 亚米级高分辨率遥感影像基本可界定地物的形态和类型, 使得遥感地物细粒度分类和精准监测成为可能。农业遥感的耕地提取对象从过去的大范围、大面积的密集耕地区向更加精准的耕地地块转变<sup>[5]</sup>。

大多数传统方法利用图像分割方法对多期、高空间分辨率和多光谱影像进行耕地提取。Rydberg 等<sup>[6]</sup>结合多

光谱遥感影像数据用基于边缘检测的图像分割技术进行耕地边界线提取。Yan 等<sup>[7]</sup>利用植被指数和边缘检测对多期遥感影像进行耕地提取。Hong 等<sup>[8]</sup>针对规则耕地设计了一套数学方法用于农田边界提取。这些方法通常需要结合多源遥感影像中耕地地块大小、形状、纹理等先验知识人为设计特征或参数。传统的提取方法多基于光谱特征的像素聚合, 本质上未有效利用图像的上下文语义、形态等高阶特征, 并且忽略了高分遥感影像的其他空间特征, 难以在复杂地形区域获取地块级耕地信息<sup>[9-12]</sup>。

深度卷积神经网络 (Deep Convolution Neural Network, DCNN)<sup>[13]</sup>可从样本集中自动学习出具有代表性特征的能力, 其为高分辨率遥感影像地块提取提供了新的思路。Wu 等<sup>[14]</sup>探索了深度学习在高分遥感影像中进行地物提取的可行性, 结果表明其相比于传统的方法具有更好的性能。Gong 等<sup>[15]</sup>设计了一种三维卷积神经网络来从遥感数据中获取时空特征, 并进行农作物的分类, 取得了良好的精度。目前很多基于 DCNN 的耕地提取方法<sup>[16-18]</sup>采用语义分割模型来获取耕地对象, 即利用了图像的纹理、光谱信息, 基于像元的同质性, 自底向上聚合形成待提取的图像对象<sup>[19]</sup>。由于耕地地块往往直接相邻, 相邻地块之间共享边界, 在这种情况下, 语义分割将产生粘连的多边形对象。分区分层分级思想<sup>[20-22]</sup>为基于高分辨率遥感影像的地块尺度的耕地提取提供了解决方案, Xia 等<sup>[23]</sup>提出了一种从高分遥感影像上提取耕地地块的

收稿日期: 2021-06-17 修订日期: 2021-09-28

基金项目: 国家重点研发计划项目 (2018YFB0505000); 国家自然科学基金项目 (41971375)

作者简介: 周楠, 博士生, 中级工程师, 研究方向为遥感智能计算。

Email: zhounan@aircas.ac.cn

\*通信作者: 沈占锋, 博士, 研究员, 研究方向为高分遥感影像信息提取与分析。Email: shenzf@aircas.ac.cn

流程,该流程利用边缘检测模型 RCF<sup>[24]</sup>和语义分割模型 U-Net<sup>[25]</sup>分别获取耕地的边缘和属性信息。这类方法在模型推理阶段所获取的耕地边缘和语义特征没有实现互联互通,当面向耕地地块狭长细小、边界模糊等遥感场景时,无法进行特征互补,导致其在地块形态精准提取效果上表现不佳。

针对上述存在的问题,本文提出了一种基于高分辨率遥感影像的针对山区复杂形态的耕地地块精准提取方法来打破“特征孤岛”的局面,实现耕地地块边缘和语义特征的互联互通,主要的思路是:级联语义分割模型和边缘检测模型,利用增强边界类和聚焦训练的方法来强化训练样本。通过训练得到有效的耕地地块提取模型,并验证其性能。

## 1 研究区及数据

### 1.1 研究区概况

本文选择湖南省邵阳市邵东县作为试验区。邵东县位于中国西南部的山地区域,地理位置东经 111°30′~112°5′,北纬 26°50′~27°28′,在邵阳市东郊,总面积 1 768.75 km<sup>2</sup>。如图 1 所示,该县境内属湘中丘陵地带,丘岗地占全县总面积的 61.18%,山地占 21.69%,平原多为溪谷平原,仅占 10.85%。研究区耕地细碎化现象严重,耕地地块细长狭小且结构复杂,是中国西南丘陵地区的一个代表性区域。

### 1.2 数据来源及预处理

试验区卫星影像来源于 Google Earth,其空间分辨率为 0.53 m,包含 RGB 三个波段。西南地区多云多雨,大多影像云量占比高,单期无云影像数据获取难度较大。因此试验所使用的影像由多期影像裁剪镶嵌而成,时间跨度从 2018 年 3 月至 2019 年 4 月。

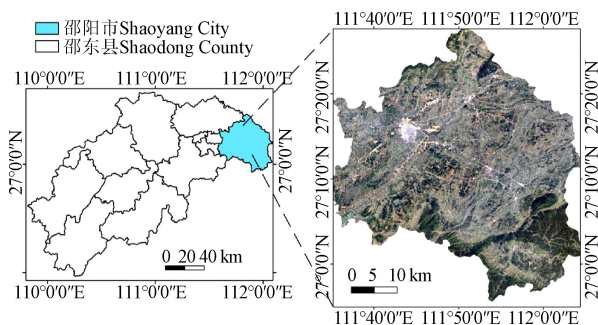


图 1 邵东县地理位置示意图

Fig.1 Geographic location diagram of the Shao Dong Country

对试验数据进行耕地样本采集,利用 ArcGIS 软件进行样本绘制,共得到 1 000 张 512×512 像素大小的影像切片。随机选取 600 张作为训练集,200 张作为验证集,200 张作为测试集。在训练阶段,每张高分影像有耕地纹理和耕地边缘两种标签,其中纹理标签为二值图,0 表示背景,1 表示耕地。耕地边缘标签为单像素宽的线条。

图 2 截取了 3 种类型样本的高分遥感影像,对其视觉特征进行说明:1)图 2a 为规则耕地,在空间分布上比较整齐,其边缘清晰,内部纹理较为均匀;2)图 2b 为

狭长耕地,其地块狭长细小,边界清晰,内部纹理均匀;3)图 2c 为复杂种植结构地块,耕地的边缘特征较为模糊且形态各异,主要依靠地块内部作物的纹理特征加以辨别。

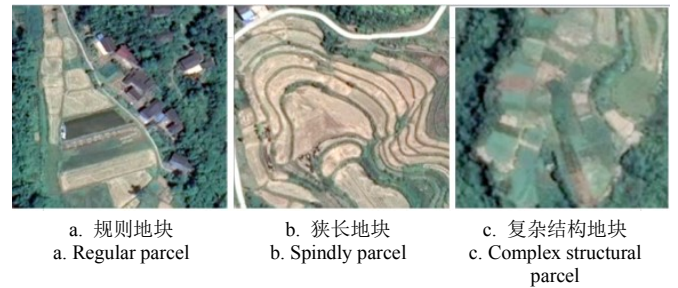


图 2 真彩色影像下的典型样本

Fig.2 Typical samples under true color images

## 2 研究方法

基于 Google Earth 高分遥感影像随机选择训练样本,并利用图形学方法增强样本边缘得到边界增强样本,接着利用样本对本文提出的级联网络模型进行聚焦训练,构建耕地地块预测模型,并预测影像上的耕地边缘和纹理信息,通过闭合边缘线构面、栅格转矢量等后处理操作获取耕地地块。耕地地块提取的整体流程如图 3 所示。

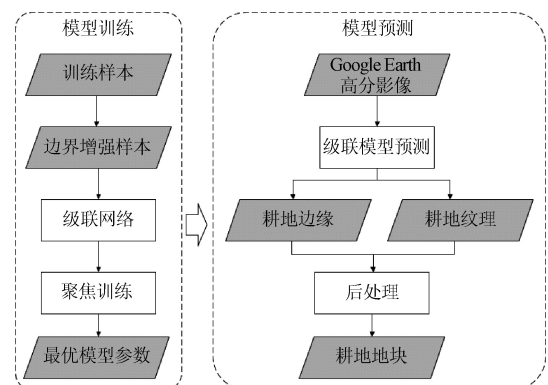


图 3 耕地地块提取流程图

Fig.3 Flowchart for extraction of cropland parcels

本文提出的耕地提取方法结合了语义分割模型和边缘检测模型的优势,并进行了 3 点改进:1)将耕地边缘作为独立于耕地地块外的新类别。2)级联语义分割网络 U-Net<sup>[25]</sup>和改进的边缘检测网络 HED<sup>[26]</sup>。3)模型聚焦训练,集中学习高分辨率遥感影像中重要但代表性不足的边缘部分。

### 2.1 边界增强

本文在耕地样本中对耕地边界进行增强操作,将耕地边界视为除背景和耕地纹理的第 3 类。在训练过程中,使用边界增强后的样本进行模型训练,得到的概率分布图将会有额外的类来表示耕地边界的概率分布,使得语义分割能够更好区分耕地地块边缘和内部区域。

### 2.2 级联网络

图 4 为本文耕地提取模型的结构,该模型可视作两阶段任务,先进行语义分割任务,再进行边缘检测任务。这类多任务网络既需要高级特征也需要低级特征<sup>[27]</sup>。所

提出的模型是一个级联的深度卷积网络，它主要分为两部分：耕地纹理提取和耕地边缘提取。


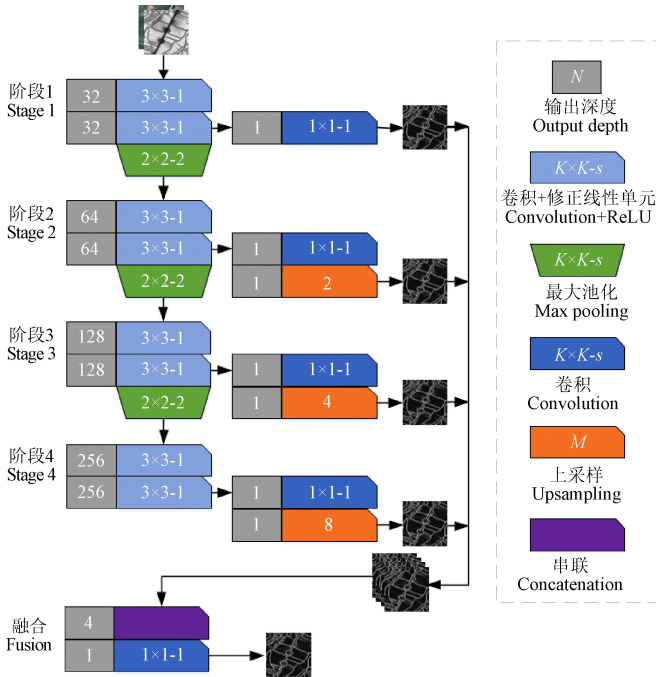


图4 级联模型结构图  
Fig.4 Architecture of the cascaded model

耕地纹理提取模型可选用任意的语义分割网络，耕地边界提取模型可选用任意的边缘检测网络。级联后的模型将耕地纹理和边缘特征进行关联，改善多任务网络的预测结果，从而实现耕地地块的精准提取。本文选用 UNet 作为语义分割网络和改进的 HED 作为边缘检测网络。在整个级联模型框架下，本文从 3 个方面对级联在 UNet 后的 HED 模型结构加以改进：1) 连接 UNet 输出层的特征图和原始图像作为模型输入；2) 1~4 阶段每个卷积层的输出深度减半；3) 丢弃阶段 5 及其相应的侧向输出模块。改进后的 HED 模型结构如图 5 所示。



注：N 为输出深度；K 为感受野大小；s 为步长大小；M 为上采样率。  
Note: N is output depth; K is the size of the receptive field; s is the size of step; M is the upsampling ratio.

图5 改进的 HED 模型结构  
Fig.5 Improved architecture of HED model

改进后的 HED 网络参数较少，改进的原因：1) 语义分割模型用于学习耕地和田坎的纹理特征，相比于原始遥感影像，其输出层生成的特征图背景相对简单，耕地边缘提取与耕地纹理提取相关，因此，一个相对较小的网络能够完成边缘检测；2) 相对于耕地纹理提取问题，耕地边缘像素远少于非边缘像素，虽然在损失层借助权重方法可提高边缘像素的比重，但在不使用预训练模型参数的情况下，深度网络容易过拟合<sup>[28]</sup>。

## 2.3 聚焦训练

聚焦训练 (Focus Weights, FW) 是借助加权交叉熵损失函数<sup>[25]</sup>来集中学习高分辨率遥感影像中重要但代表性不足的边缘像素，提高边缘检测精度。

$$L(y, z) = \sum_{p \in \Omega} \sum_{i=0}^C \omega(p, \theta) y(p, i) \log \text{smax}_i(z(p)) \quad (1)$$

$$\text{smax}_i(u) = \exp(u_i) / \sum_{j=0}^C \exp(u_j) \quad (2)$$

式中  $\text{smax}(u)$  作用到  $u$  的 softmax 函数； $\log$  表示算法函数； $\omega(p, \theta)$  表示由  $p$  和  $\theta$  为参数的已知权重； $y(p, i)$  表示分类函数； $z(p)$  表示像素  $p$  的未知特征向量

本次选用基于距离变换函数的权重映射。

$$W(p, \beta) = \omega_0(p) \left( 1 - \min \left( \frac{\phi_g(p)}{\beta}, 1 \right) \right) \quad (3)$$

式中  $\beta$  表示控制轮廓向外衰减的参数； $\omega_0(p)$  表示调节类不平衡，与类中的像素成反比； $\phi_g(p)$  表示距离变换函数。

## 3 结果与分析

### 3.1 环境与模型训练

硬件平台为 I9-10900k CPU、64GB 内存和 NVIDIA GeForce RTX 3080(10G) GPU，本文设计的深度学习网络均在 PyTorch 框架下搭建。模型训练阶段采用动量为 0.9 的随机梯度下降算法进行优化，学习率计划采用周期学习率<sup>[29]</sup>，最大学习率为  $1 \times 10^{-3}$ ，最小学习率为  $1 \times 10^{-8}$ ，循环周期为 40 轮，共 3 个循环，批次大小为 4，使用加权交叉熵损失函数。为了排除其他的干扰因素，本文试验均采用相同的数据增强方法。在本文的试验中，所采取的数据增强手段有随机尺度裁剪、随机旋转、镜像。

### 3.2 评价指标

为了客观合理地评价模型在高分辨遥感影像中进行耕地提取的精度，本文使用完整度 (Completeness, Comp)、正确度 (Correctness, Corr) 和质量 (Quality, Qual)<sup>[30]</sup>来评价本文方法所提取耕地地块边界线与真值的吻合程度，使用像素准确率 (Pixel Accuracy, PA)、交并比 (Intersection Over Union, IOU) 和 Kappa 系数评价耕地地块的提取精度。

#### 3.2.1 线状评价指标

完整度是召回率 (Recall) 的一种变体，在所提取的边界线进行缓冲区建设，用该缓冲区与真值 (Ground truth) 边界线重叠部分长度和真值边界线长度的百分比表示；正确度是准确率的变体，在真值边界线进行缓冲区建设，用该缓冲区与提取的边界线重叠部分长度和提取边界线长度的百分比表示；质量是一个结合完整度和正确度的总体指标。以上指标计算公式为

$$\text{Comp} = \frac{L_{mr}}{L_r} \quad (4)$$

$$\text{Corr} = \frac{L_{me}}{L_e} \quad (5)$$



$$\text{Qual} = \frac{L_{me}}{L_e + L_r - L_{mr}} \quad (6)$$

式中  $L_{mr}$  表示实际耕地边界与所提取耕地边界重叠的长度； $L_{me}$  表示所提取的耕地边界与实际耕地边界重叠的长度； $L_r$  和  $L_e$  分别表示实际和提取耕地边界的长度。

### 3.2.2 面状评价指标

像素准确率 (PA) 能够表示像素点分类的精度, 用影像中分类正确的像素点数量与像素点总数的百分比值来表示; 交并比 (IOU) 是语义分割模型的标准评价指标, 用来表示实际标注区域与预测区域之间的重合度。

$$\text{PA} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (7)$$

式中 TP 和 FP 分别表示正确预测和错误预测的像素数量。

$$\text{IOU} = \frac{A \cap B}{A \cup B} \quad (8)$$

式中  $A$  表示预测区域;  $B$  表示实际标注区域。

### 3.3 耕地地块提取结果

邵东县的耕地地块提取结果如图 6 所示, 共得到 77.43 万个地块图斑, 耕地总面积为 50 800  $\text{hm}^2$ 。在 200 张  $512 \times 512$  像素大小的测试集上进行精度评定, 计算边界提取精度 Qual 为 61.37%, PA 为 92.91%。

从耕地地块提取结果的细节图可以看出, 地块边缘与真值吻合度较高, 部分细长狭小、模糊的地块存在错提、漏提的情况, 整体提取结果较好 (图 7)。

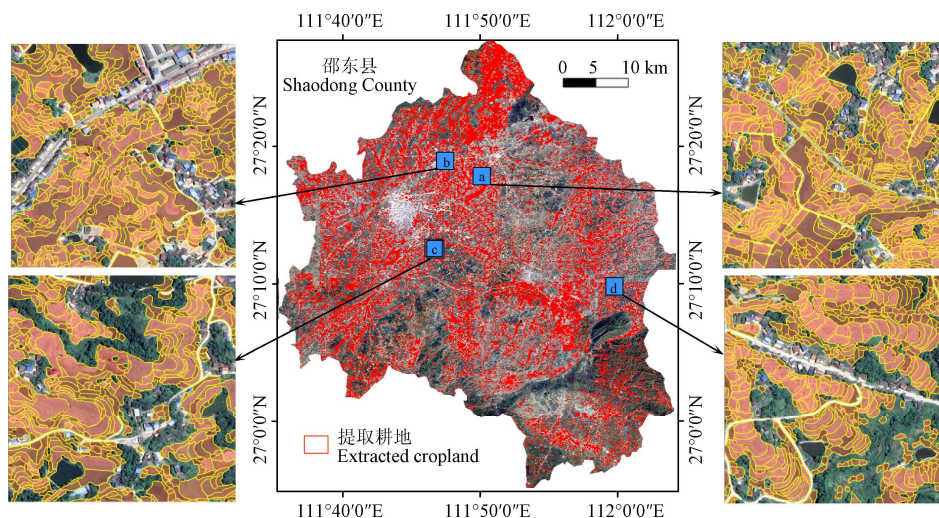
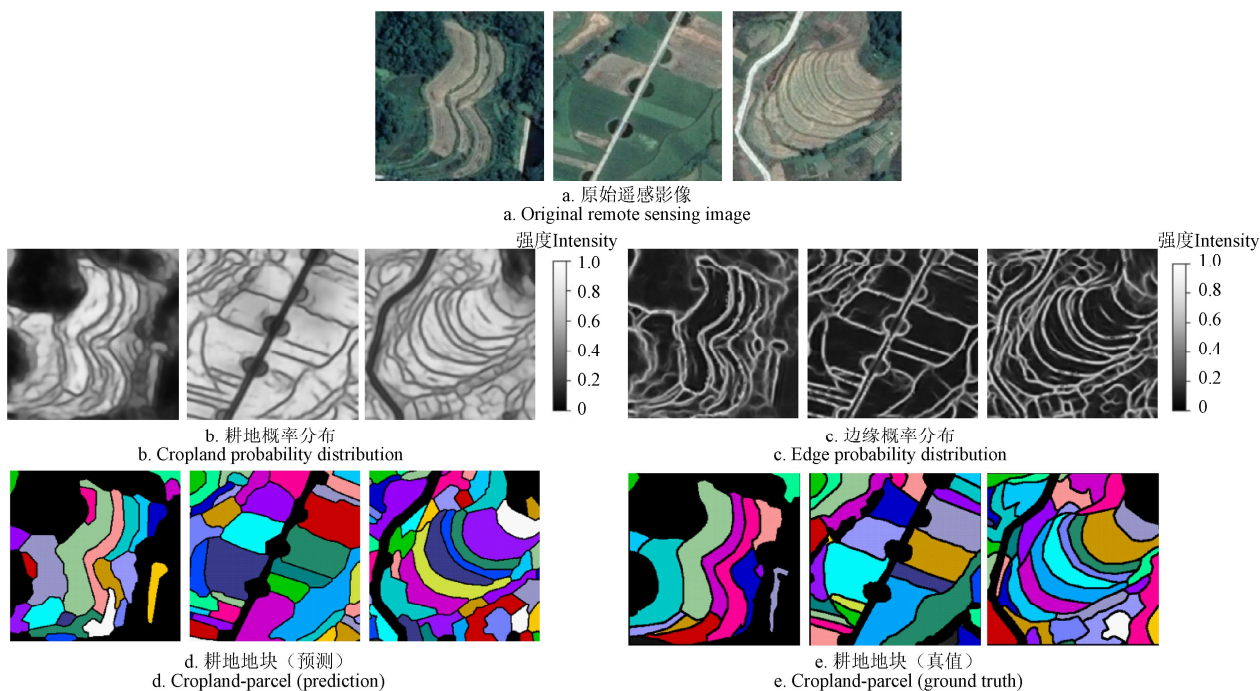


图 6 耕地提取结果

Fig.6 Cropland extraction results



注: 不同颜色的图斑表示不同的地块。

Note: Patches of different colors represent different parcels.

图 7 耕地提取过程展示

Fig.7 Display of cropland extraction process

3.4 与现有方法的耕地地块提取结果比较

在现有方法中,通过边缘检测模型获取的耕地边缘线构建面状地块,并利用语义分割模型获取的耕地语义信息与其进行匹配,来获取地块的耕地属性。为验证本文方法的有效性,将本文方法与现有基于高分遥感影像的耕地地块提取方法进行对比,选择具有代表性的 DexiNed<sup>[31]</sup>和 RCF<sup>[23]</sup>边缘检测网络进行对比试验,其中 DexiNed 为现有边缘检测模型中的最优模型。为便于试验对比,语义分割网络选用 UNet,与本文中的级联语义分割网络相同。

如表 1 和表 2 所示,本文方法在测试集上取得了各个评价指标的最优值,线状评价指标 Comp、Corr 和 Qual 分别为 83.45%、70.16%、61.37%,与 DexiNed 和 RCF 相比均有一定程度的提高,分别提高 7.22 和 5.65、0.16 和 14.72、4.09 和 13.91 个百分点。面状评价指标 PA、IOU 和 Kappa 分别为 92.91%、82.84%、84.93%。本文方法与 DexiNed 和 RCF 相比均有一定程度的提高,其 PA 分别提高 1.98、4.28 个百分点,IOU 分别提高 3.82、8.01 个百分点,Kappa 分别提高 4.04、8.72 个百分点。

表 1 试验结果的线状评价指标对比

Table 1	Line evaluation index of experimental results			%
方法 Method	完整度 Completeness	正确度 Correctness	质量 Quality	
RCF <sup>[23]</sup>	77.8	55.44	47.46	
DexiNed <sup>[31]</sup>	76.23	70.00	57.28	
本文方法(无聚焦训练) Our method without focus training	80.72	72.24	61.36	
本文方法(有聚焦训练) Our method with focus training	83.45	70.16	61.37	

表 2 试验结果的面状评价指标对比

Table 2	Poly evaluation index of experimental results			%
方法 Method	像素准确率 Pixel accuracy	交并比 Intersection of union	Kappa 系数 Kappa coefficient	
RCF <sup>[23]</sup>	88.63	74.83	76.21	
DexiNed <sup>[31]</sup>	90.93	79.02	80.89	
本文方法(无聚焦训练) Our method without focus training	92.56	82.37	84.29	
本文方法(有聚焦训练) Our method with focus training	92.91	82.84	84.93	

图 8 为耕地地块边缘强度提取效果,为清楚观察提取结果,选取部分测试地块的预测边缘强度,通过图片可以看出,本文方法在视觉上具有较好的效果。

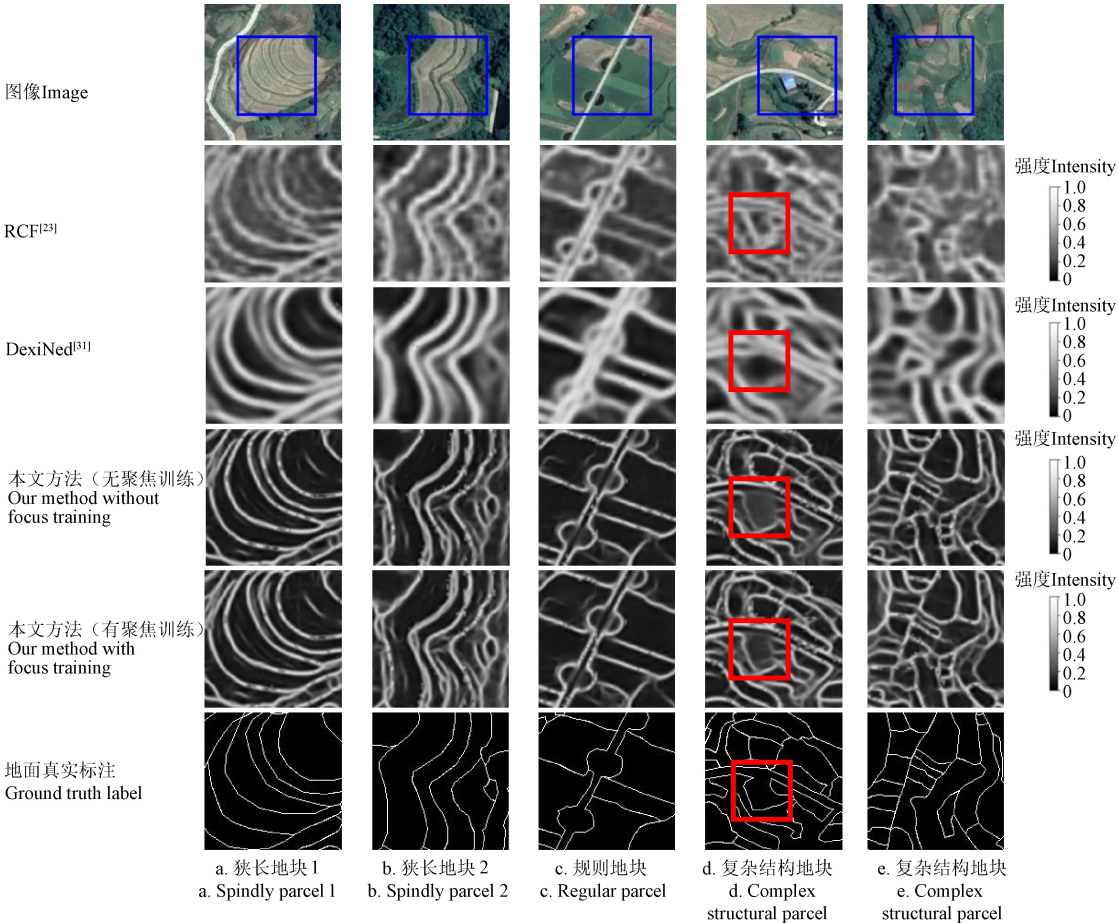


图 8 耕地边缘的细节展示  
Fig.8 Details display of cropland edge

通过图 8 可看出本文方法对图 2 中所示的 3 种耕地地块形态在测试地块上都进行了有效的学习,在复杂遥感场景下具有较好的泛化能力。通过图 8a、8b、8c、8d 和

8e 可以看出该方法所提边缘强度较现有方法更加清晰,在狭长细小的耕地地块提取上表现更好;由图 8d 红框可看出该方法对非耕地类的地块边界有很好的过滤效果;通过

图 8e 可以看出该方法在复杂种植结构地块上边缘强度也可以正常预测。

## 4 讨论

西南山区耕地大多为破碎化地块, 地块细小狭长, 与自然地物接边的地块无明显人工构筑痕迹, 导致其在高分辨率遥感影像上呈现边缘模糊, 这给大范围耕地地块自动化提取带来了挑战。现有的基于高分影像的耕地地块提取方法<sup>[23]</sup>割裂了耕地纹理和边缘的联系, 使得现有方法在上述耕地地块类型提取中表现不佳, 在测试集中提取精度 Qual 为 47.46%、IOU 为 74.83%。本研究仅基于耕地纹理和边缘特征融合进行耕地地块提取的精度 Qual 为 61.36%、IOU 为 82.37%, 结合聚焦训练策略强化耕地边缘, 精度 Qual 为 61.37%、IOU 为 82.84%。先前耕地地块提取研究中, 首先利用边缘检测模型获取的耕地边缘线构建面状地块, 并利用语义分割模型赋予地块属性信息, 这种两阶段方法导致耕地边缘线提取过程中缺乏语义特征的监督, 使得结果中包含较多的非耕地类边界, 高分影像中“同物异谱”和“同谱异物”的特点使得这类问题更加突出。本研究级联语义分割和边缘检测模型, 边缘特征在语义特征导向下进行模型训练, 本文方法能够有效过滤非耕地类边界。

但是本研究仍存在一些局限性。西南山区多云多雨, 难以获取单一时期的高分影像, 为了获取无云影像, 利用多期影像进行镶嵌, 由于不同时期影像存在色差, 镶嵌效果存在一些不确定性。在未来研究中, 将考虑光学协同雷达影像, 并结合迁移学习改善影像色差问题, 实现山区耕地地块快速精准提取。

## 5 结论

精准的耕地地块信息对于国家制定农业政策具有重要参考价值, 受限于山地丘陵地区破碎化和复杂的种植结构, 现有的耕地地块提取方法无法满足实际应用需求。基于耕地边缘和语义特征融合的思路, 本研究实现了耕地地块的精准提取:

- 1) 线模型与面模型级联可有效融合线特征与面特征, 提取精度明显优于单独使用线模型或者面模型;
- 2) 损失函数分为线损失项和面损失项两部分, 给予线损失项较大权重能够促使模型聚焦于边缘线的训练, 同时补充部分面特征, 有效解决了狭长地块边界模糊的问题;
- 3) 在影像源质量有保障的前提下, 该研究提出的方法可通过增补少量样本数据强化训练, 实现山地丘陵地物地块级尺度耕地快速精准提取, 具有一定的泛化能力。

### [参 考 文 献]

- [1] Aguilar M A, Saldaña M M, Aguilar F J. GeoEye-1 and WorldView-2 pan-sharpened imagery for object-based classification in urban environments[J]. *International Journal of Remote Sensing*, 2013, 34(7): 2583-2606.
- [2] Shi Y, Lou Y, Zhang Z, et al. Estimation of methane emissions based on crop yield and remote sensing data in a paddy field[J]. *Greenhouse Gases: Science and Technology*, 2020, 10(1): 196-207.
- [3] 吴炳方. 中国农情遥感速报系统[J]. *遥感学报*, 2004(6): 481-497.  
Wu Bingfang. China crop watch system with remote sensing[J]. *Journal of Remote Sensing*, 2004(6): 481-497. (in Chinese with English abstract)
- [4] Waldner F, Diakogiannis F I. Deep learning on edge: Extracting field boundaries from satellite images with a convolutional neural network[J]. *Remote Sensing of Environment*, 2020, 245: 111741.
- [5] 刘巍, 吴志峰, 骆剑承, 等. 深度学习支持下的丘陵山区耕地高分辨率遥感信息分区分层提取方法[J]. *测绘学报*, 2021, 50(1): 105-116.  
Liu Wei, Wu Zhifeng, Luo Jiancheng, et al. A divided and stratified extraction method of high-resolution remote sensing information for cropland in hilly and mountainous areas based on deep learning[J]. *Acta Geodaetica et Cartographica Sinica*, 2021, 50(1): 105-116. (in Chinese with English abstract)
- [6] Rydberg A, Borgefors G. Integrated method for boundary delineation of agricultural fields in multispectral satellite images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, 39(11): 2514-2520.
- [7] Yan L, Roy D P. Automated crop field extraction from multi-temporal Web Enabled Landsat Data[J]. *Remote Sensing of Environment*, 2014, 144: 42-64.
- [8] Hong R, Park J, Jang S, et al. Development of a parcel-level land boundary extraction algorithm for aerial imagery of regularly arranged agricultural areas[J]. *Remote Sensing*, 2021, 13(6): 1167.
- [9] Myint S W, Gober P, Brazel A, et al. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery[J]. *Remote Sensing of Environment*, 2010, 115(5): 1145-1161.
- [10] Zhang X, Wang Q, Chen G, et al. An object-based supervised classification framework for very-high-resolution remote sensing images using convolutional neural networks[J]. *Remote Sensing Letters*, 2018, 9(4): 373-382.
- [11] Hao P, Zhan Y, Wang L, et al. Feature selection of time series MODIS data for early crop classification using random forest: A case study in Kansas, USA[J]. *Remote Sensing*, 2015, 7(5): 5347-5369.
- [12] Gao F, Anderson M C, Zhang X, et al. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery[J]. *Remote Sensing of Environment*, 2017, 188: 9-25.
- [13] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436.
- [14] Wu Tianfu, Hu Wei, Huang Yangyu, et al. Deep convolutional neural networks for hyperspectral image classification[J]. *Journal of Sensors*, 2015, 2015: 1-12.
- [15] Gong Jianya, Ji Shunping. Photogrammetry and deep learning[J]. *Journal of Geodesy and Geoinformation Science*, 2018(1): 1-15.
- [16] 鲁恒, 付萧, 贺一楠, 等. 基于迁移学习的无人机影像耕地信息提取方法[J]. *农业机械学报*, 2015, 46(12): 274-279.  
Lu Heng, Fu Xiao, He Yinan, et al. Cultivated land information extraction from high resolution UAV images based on transfer learning[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2015, 46(12): 274-279. (in Chinese with English abstract)
- [17] Garcia-Pedrero A, Lillo-Saavedra M, Rodriguez-Esparragon D, et al. Deep learning for automatic outlining agricultural parcels: Exploiting the land parcel identification system[J]. *IEEE Access*, 2019, 7: 158223-158236.
- [18] Masoud K M, Persello C, Tolpekin V A. Delineation of agricultural field boundaries from Sentinel-2 images using a novel super-resolution contour detector based on fully convolutional networks[J]. *Remote sensing*, 2020, 12(1): 1-16.



- [19] 巫兆聪, 胡忠文, 张谦, 等. 结合光谱、纹理与形状结构信息的遥感影像分割方法[J]. 测绘学报, 2013, 42(1): 44-50.  
Wu Zhaocong, Hu Zhongwen, Zhang Qian, et al. On combining spectral, textural and shape features for remote sensing image segmentation[J]. Acta Geodaetica et Cartographica Sinica, 2013, 42(1): 44-50. (in Chinese with English abstract)
- [20] 骆剑承, 吴田军, 吴志峰, 等. 遥感大数据智能计算[M]. 科学出版社, 2020.
- [21] Wei L, Jian W, Jiancheng L, et al. Farmland parcel mapping in mountain areas using time-series SAR data and VHR optical images[J]. Remote Sensing, 2020, 12(22): 3733.
- [22] Liu H, Luo J, Sun Y, et al. Contour-oriented cropland extraction from high resolution remote sensing imagery using richer convolution features network[C]//2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics), Istanbul, Turkey: IEEE, 2019.
- [23] Xia L, Luo J, Sun Y, et al. Deep extraction of cropland parcels from very high-resolution remotely sensed imagery[C]//2018 7th International Conference on Agro-Geoinformatics (Agro-Geoinformatics), Hangzhou, China: IEEE, 2018: 405-409.
- [24] Liu Y, Cheng M, Hu X, et al. Richer convolutional features for edge detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 41(8): 1939-1946.
- [25] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//2015 18th International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, Germany: 2015: 234-241.
- [26] Xie S, Tu Z. Holistically-nested edge detection[J]. International Journal of Computer Vision, 2015, 125(3): 3-18.
- [27] Yang J, Price B, Cohen S, et al. Object contour detection with a fully convolutional encoder-decoder network[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, Seattle, WA: IEEE, 2016: 193-202.
- [28] Liu Y, Yao J, Lu X, et al. RoadNet: learning to comprehensively analyze road networks in complex urban scenes from high-resolution remotely sensed images[J]. IEEE Transactions on Geoscience Remote Sensing, 2018, 57: 2043-2056.
- [29] Smith L. Cyclical learning rates for training neural networks[C]//2017 17th IEEE Winter Conference on Applications of Computer Vision, Santa Rosa, CA: IEEE, 2017: 464-472.
- [30] Wiedemann C, Heipke C, Mayer H, et al. Empirical evaluation of automatically extracted road axes[J]. Empirical Evaluation Methods in Computer Vision, 1998, 12: 172-187.
- [31] Soria X, Riba E, Sappa A. Dense extreme inception network: towards a robust CNN model for edge detection[C]//2020 IEEE Winter Conference on Applications of Computer Vision, Snowmass, CO: IEEE, 2020: 1912-1921.

## Accurate extraction method for cropland in mountainous areas based on field parcel

Zhou Nan<sup>1,2</sup>, Yang Peng<sup>1</sup>, Wei Chunshan<sup>1</sup>, Shen Zhanfeng<sup>1,2\*</sup>, Yu Juanjuan<sup>3</sup>, Ma Xiaoyu<sup>4</sup>, Luo Jiancheng<sup>1,2</sup>

(1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100101, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China; 3. School of Earth Sciences and Engineering, Hohai University, Nanjing 211100, China; 4. School of Earth Sciences and Engineering, Hebei University of Engineering, Handan 056000, China)

**Abstract:** In mountainous and hilly areas, cultivated land resources are scarce, and the phenomenon of cultivated land fragmentation is serious. The long and narrow arable land plots are complex in structure, which makes it difficult to obtain the information of cultivated land at the land level quickly and accurately, and hinders the application of precise digital agricultural services based on high resolution remote sensing images in mountainous and hilly areas. Parcel-level cultivated land information can intuitively show the spatial distribution, boundary details of farmland, and is of great significance for precision agriculture management, distribution of planting subsidies, and agricultural resource survey. Existing edge detection/semantic segmentation networks-based farmland extraction methods ignore the structural features of the parcel, thus have limit performance for handling narrow and small plots, and there is also a blurring boundary problem. To address these issues, we proposed an accurate extraction method of cropland in mountainous area based on geographic parcels. This method combines the advantages of semantic segmentation and edge detection, and effectively extracts and integrates the linear features of the boundary and the internal texture features of the parcel, so as to improve the recognition accuracy of the cultivated land. The main features of the model in this paper are as follows: 1) The edge of cultivated land is regarded as a new class independent of cultivated land parcels, so that the semantic segmentation network can better distinguish the edge and internal area of cultivated land parcels; 2) A cascaded semantic segmentation and edge detection network is introduced to correlate the prediction of cultivated land surface and line, realize the fusion of boundary and texture features of cultivated land parcels and strengthen the edge features of cultivated land, so as to improving the accuracy of cultivated land block edge detection; 3) A focus training technique is proposed to address the problem that the edge pixels of cultivated land are far fewer than non-edge pixels, by enforcing the model pay more attention to the important but underrepresented edge pixels in high resolution remote sensing images in the training process, so as to improve the edge detection accuracy. We conduct experiments in Shaodong County, Hunan Province in the southwest mountainous area, using the Google Earth high-resolution remote sensing images as the data source, with a spatial resolution of 0.53 m. After manual selection, a total of 1000 512×512 image patches are obtained. Among them, 600 pieces are used as the training set, 200 pieces are used as the verification set, and 200 pieces are used as the test set. Experimental results show that the presented model achieves satisfying results with an overall accuracy of 92.91% and IoU (Intersection-Over-Union) of 82.84% on the test set, which was 4.28 percentage points and 8.01 percentage points higher than the baseline method respectively. Compared with the existing methods, the cultivated land extracted in this study is more consistent with the actual distribution pattern of cultivated land, which provides a practical method for accurate extraction of cultivated land information at the plot scale in mountainous and hilly regions.

**Keywords:** remote sensing; high resolution image; hilly and mountainous areas; semantic segmentation; edge detection; cropland-parcel extraction