

基于高分辨率遥感和多源数据融合的耕地边界精准提取方法研究

孙 杰^{1,2}, 茹 亮^{1,2}, 梁 帅^{1,2}, 武 帅^{1,2}, 李玄辉^{1,2*}

(1. 中国地质调查局地球物理调查中心, 河北 廊坊 065000

2. 中国地质调查局地球浅地表探测技术创新中心, 河北 廊坊 065000)

摘 要:耕地边界精准提取是自然资源管理与粮食安全评估的关键技术。针对传统方法在复杂地形中精度不足的问题,提出基于高分辨率遥感和多源数据融合的耕地边界提取方法。通过 PCA/ICA 联合降维消除数据冗余,构建“深度学习初步分割—多源特征边界优化—形态学后处理”技术链路,提升复杂场景下的边界连续性与定位精度。实验选取江苏平原、云南山地、黑龙江黑土区验证,结果表明:融合多源数据后,模型平均 IoU 达 0.92,较单一深度学习模型提升 6.9%–9.5%,边界误差从 8.7m 降至 3.2m 以下,Kappa 系数超 0.85,显著优于随机森林、阈值分割等传统方法。研究构建的多源数据融合框架与优化技术为耕地动态监测提供了高效解决方案。

关键词:高分辨率遥感;多源数据融合;耕地边界提取

中图分类号:F301.21 **文献标志码:**A **文章编号:**1672-2736(2025)06-0034-9

0 引言

耕地边界精准提取作为自然资源管理、国土调查和粮食安全评估的关键技术环节,对土地资源精细化管理意义重大^[1]。近年来,高分辨率遥感技术持续突破,如国产高分系列卫星(GF-6)和商业遥感卫星(如 MaxarWorldView-4)的空间分辨率已达亚米级,为耕地边界提取提供了高精度数据基础。然而,复杂地表环境与传统方法的固有缺陷,仍严重制约着提取精度的发展。

传统提取方法主要包含目视解译、基于规则的影像分割和浅层机器学习模型。目视解译依赖人工判读,效率低且主观性强,据统计,人工解译每平方公里耕地边界耗时达 3–5 小时,难以满足大范围自动化提取需求;基于规则的方法,如边缘检测、阈值分割,需手工设计光谱或纹理特征,在作物轮作频繁、边界模糊区域易出现误判,误判率可高达 20%–30%;随机森林等机器

学习方法虽提升了特征利用效率,但因依赖人工特征工程,在地形破碎(如西南梯田)或地物混杂(如平原水网区)场景下,边界连续性和定位精度显著下降^[2]。

随着深度学习在遥感领域的应用,U-Net^[3]、DeepLabv3+^[4]等网络通过端到端学习自动提取影像特征,在遥感语义分割中展现出显著优势。美国地质调查局(USGS)利用深度学习对 Landsat8 影像进行耕地提取,平均精度达 85%^[5];欧洲空间局(ESA)结合 Sentinel-2 多光谱数据与深度学习,实现了区域级耕地动态监测^[6]。但现有研究多聚焦单一遥感数据,对地形、土壤、气象等多源数据的融合利用不足。席志龙等^[7]尝试将地形因子或植被指数引入分割模型,采用简单数据叠加方式,未能充分挖掘多源数据间的互补性。与之不同,Li Y 等^[8]提出的多源数据融合方法,通过时空对齐与加权融合策略,提升了模型对复杂环境的适应性,但仍存

基金项目:中国地质调查局项目(DD20230528)。

在特征冗余问题。

针对现有耕地边界提取方法在复杂场景下的精度瓶颈,本文提出融合高分辨率遥感与多源数据的新方法。通过 PCA/ICA 联合降维,实现多源特征融合,去除数据冗余并保留互补信息,增强模型对多模态数据的适应性;设计“深度学习初步分割—多源特征边界优化—形态学后处理”技术链路,重点提升梯田、水网等复杂地形区域的边界提取精度。研究的两大创新点为:构建新型多源数据融合框架和优化技术链路,研究成果将为耕地动态监测与资源精细化管理提供技术支持。

1 研究方法与技术框架

1.1 数据来源与预处理

高分辨率遥感影像数据是耕地边界提取的核心数据源,本文采用 Sentinel-2 和 GF-2 卫星影像作为主要数据源^[9]。Sentinel-2 影像获取时间为 2020-2023 年作物生长季(5-10 月),覆盖江苏、云南、黑龙江三大实验区,包含 13 个光谱波段(空间分辨率 10m/20m/60m),本文主要使用 10m 分辨率的可见光-近红外波段(B2/B3/B4/B8)。GF-2 影像获取时间为 2021-2023 年无云时段,其全色波段分辨率 1m、多光谱 4m,通过 Gram-Schmidt 融合生成 1m 分辨率真彩色影像。辅助数据包括:(1)地形数据采用 NASA ASTER GDEMv3(30m 分辨率,垂直精度 $\pm 5\text{m}$),提取坡度(计算窗口 3×3 ,精度 $\pm 1^\circ$)、坡向等地形因子;(2)土壤数据来自 HWSDv1.2 土壤数据库(1km 分辨率),包含 12 类土壤质地和有机质含量(0-100cm 土层);(3)气象数据来自中国气象局 2020-2023 年逐日观测数据,空间插值至 30m 格网,包含降水量(精度 $\pm 0.1\text{mm}$)和平均温度(精度 $\pm 0.5^\circ\text{C}$)。

数据预处理流程如下所示,所有遥感数据均经过标准化处理。

(1)辐射校正:采用 ENVI5.6 的辐射定标模块,将 Sentinel-2 L1C 数据转换为表观反射率,GF-2 数据通过卫星参数文件实现辐射定标;

(2)大气校正:针对 Sentinel-2 数据采用 6S 大气校正模型(气溶胶类型大陆型,能见度 40km),GF-2 数据采用 FLAASH 模型(中纬度夏季大气模式);

(3)几何校正:以 GF-2 全色影像为基准,通过 ERDAS2015 的 Auto Sync 模块进行配准。在每景影像中选取 25 个均匀分布的地面控制点(GCPs,来源于研究区 1:10000 地形图),采用二阶多项式变换模型,配准误差控制在 0.5 个像元内(RMS $\leq 5\text{m}$)。DEM 数据通过 ArcGIS10.8 的 Project Raster 工具统一到 WGS84_UTM 坐标系。

多源数据融合是提升耕地边界提取精度的重要手段,本文收集地形数据、土壤类型数据和气象数据等多源数据,并通过空间配准和特征融合方法将这些数据与高分辨率遥感影像进行融合。地形数据包括数字高程模型(DEM)和坡度、坡向等地形因子,用于分析地形对耕地边界的影响;土壤类型数据提供土壤质地、肥力等信息,帮助区分耕地与其他地表覆盖类型;气象数据包括降水量、温度等气象因子,用于分析气象条件对耕地边界的影响。多源数据的融合方法包括空间配准和特征融合,空间配准将多源数据统一到相同的空间参考系下,确保数据空间一致性;特征融合则利用主成分分析(PCA)和独立成分分析(ICA)等方法将多源数据的特征进行融合^[10],生成综合特征图,用于后续的边界优化。

1.2 基于深度学习的耕地区域初步提取

在基于深度学习的耕地边界提取研究中,U-Net 和 DeepLab 是两类核心的语义分割模型。U-Net 的 U 型结构十分独特^[11,12],收缩路径借助卷积与池化,降低特征图分辨率并增加通道数,以此提取高级语义特征;扩张路径通过上采样恢复分辨率,同时融合收缩路径的高分辨率特征,保留细节,对小样本数据集表现优异,契合耕地边界提取对细节的高要求。DeepLab 系列基于深度卷积神经网络,以 DeepLabv3+ 为例^[13],其编码器利用空洞卷积金字塔(ASPP),通过不同采样率并行采样特征图,获取多尺度上下文信息,解码器融合低层次特征并上采样实现精准分

割。在基于深度学习的耕地边界提取研究中,采用 U-Net 与 DeepLabv3+ 开展对比实验并定制化调整参数:U-Net 为 5 层编码器-解码器结构,初始通道数 64;DeepLabv3+ 以 ResNet-101 为主干,ASPP 模块膨胀率为[6,12,18]。训练时,优化器用 Adam,U-Net、DeepLabv3+ 学习率分别为 $1e-4$ 、 $5e-5$,批量大小设为 8 和 4,损失函数为 Dice 与交叉熵损失 1:1 融合。数据增强采用翻转、旋转等操作,正则化结合早停法与 Dropout。人工标注 1200 张 512×512 像素影像,按 8:1:1 划分数据集。训练监控 IoU、Kappa 系数等指标^[14],通过消融实验量化模块贡献。

训练好的模型具备对高分辨率遥感影像的特征提取与耕地区域分割能力。输入新影像后,模型在收缩路径提取低级特征,卷积层加深后组合成高级语义特征;在扩张路径融合高级与低级特征,上采样恢复分辨率并对像素分类,实现耕地区域分割。例如在包含多种地物的影像中,模型能依据基于光谱、纹理及空间结构等特征自动分割耕地边界。不过,因实际影像存在噪声、边界模糊等问题,初步分割结果需结合多源数据融合和后处理算法优化^[15]。

与传统机器学习方法(随机森林 RF^[16]、支持向量机 SVM^[17])及单一深度学习模型(仅用遥感数据的 U-Net/DeepLabv3+)相比,本文方法优势显著:特征提取与融合上,借 PCA/ICA 自动提取多源数据主成分与独立特征,融合后特征维度从 12 维降至 6 维,计算效率提升 40%,江苏平原区 IoU 较 RF 提升 15.2%;空间配准通过二阶多项式变换,使土壤数据配准误差从 $\pm 15\text{m}$ 降至 $\pm 2.3\text{m}$,DEM 坡度精度优化至 $\pm 0.9^\circ$;后处理结合多源特征,让云南梯田区边界误差从 8.7m 降至 3.2m,破碎边界连接率提升 22%,多云天气误分割像素减少 35%;泛化能力上,三类场景平均 IoU 达 0.92,较 U-Net、DeepLabv3+ 分别提升 9.5%、6.9%,Kappa 系数超 0.85,优于传统方法(SVM 平均 Kappa 0.71),工程实用性强。

1.3 多源数据融合与边界优化

在耕地边界提取过程中,多源数据的有效运

用极为关键。本文采用地形数据(如 DEM、坡度、坡向)、土壤类型数据(土壤质地、肥力等)和气象数据(降水量、温度等)作为多源数据来源。由于这些数据来源不同,其空间参考系与特征表示存在差异,因此本文首先对多源数据进行空间配准和特征融合处理,具体过程如下:

空间配准的目的是将多源数据统一到相同的空间参考系下,以确保数据空间一致性。本文以高分辨率遥感影像的空间参考系(WGS84 坐标系)为基准,对其他多源数据进行坐标转换。具体步骤如下:

(1)地面控制点选取:在遥感影像和多源数据中选取至少 20 个均匀分布的地面控制点(GCPs),确保控制点覆盖研究区域的各个角落。

(2)坐标转换模型选择:根据研究区域的地形复杂度和数据特点,选择多项式变换模型进行坐标转换。本文采用二阶多项式变换模型,其数学表达式为:

$$\begin{aligned} X &= a_0 + a_1x + a_2y + a_3x^2 + a_4xy + a_5y^2 \\ Y &= b_0 + b_1x + b_2y + b_3x^2 + b_4xy + b_5y^2 \end{aligned} \quad (2)$$

其中, X 和 Y 为目标坐标系坐标, x 和 y 为源坐标系坐标, a_i 和 b_i 为模型参数。

空间配准完成后,本文利用主成分分析(PCA)和独立成分分析(ICA)对多源数据进行特征融合。首先,对多源数据(DEM、坡度、坡向、土壤类型、降水量、温度等)进行标准化处理以消除量纲差异,随后计算标准化数据的协方差矩阵并进行特征分解,得到特征值和特征向量,根据特征值大小排序选择前 3 个主成分(累计贡献率超过 85%)作为融合后的特征;接着,通过对白化处理后的数据构建协方差矩阵并进行特征值分解,利用 Fast ICA 算法迭代优化分离矩阵^[18,19],从而提取相互独立的成分并生成独立成分图;最后,将 PCA 和 ICA 的结果以权重系数分别为 0.6 和 0.4 进行加权融合,生成综合特征数据集,以平衡主成分信息和独立成分信息,为后续边界优化提供数据支持。

基于融合后的多源数据,运用边缘检测算法优化耕地边界。例如 Canny 边缘检测算法,先通




图1 多源数据融合与边界优化流程图




图2 后处理与边界细化流程图

过高斯滤波平滑图像减少噪声,再算图像梯度幅值与方向,进行非极大值抑制保留真实边缘像素,最后经双阈值检测确定边缘。将融合后的综合特征图输入其中,由于融合数据融入丰富地形、土壤及气象信息,能充分利用土壤类型变化、地形起伏及不同气象条件下耕地与周边地物光谱、纹理差异,让边缘检测算法更精准识别耕地与其他地物边界,避免单一数据源导致的边界误判或不精确问题。多源数据融合与边界优化流程如图1所示。

1.4 后处理与边界细化

在基于融合数据完成边缘检测后,提取的耕地边界常受噪声干扰,影响其准确性与连续性。为解决此问题,中值滤波算法被广泛应用。该算法以特定大小窗口在图像中滑动,将窗口内像素值排序后,取中间值作为窗口中心像素新值,能有效去除因传感器误差或数据传输干扰产生的椒盐噪声等孤立噪点,且很好保留图像边缘信息,使耕地边界更加平滑。此外,高斯平滑也是常用算法,它依据高斯函数对图像加权平均,窗口中心附近像素权重更大,可减少边界锯齿,让耕地边界更自然^[20-21]。不过,使用时要合理选择参数,参数过大易使边界过度模糊、丢失重要细节,过小则平滑效果欠佳。因此,本文最终选择中值滤波窗口大小为3×3像素,高斯平滑窗口大小为5×5像素,标准差为1.0。这些参数在去除噪声的同时,能够有效保留边界细节,避免

边界过度模糊或平滑效果不足的问题。

边界细化对精确耕地边界位置、提升准确性至关重要。形态学细化算法是常用手段,通过一系列腐蚀和膨胀操作,逐步去除边界冗余像素,使边界达单像素宽度。如用结构元素对边界图像先腐蚀去除外侧像素,再膨胀恢复部分丢失信息,反复操作实现边界细化。同时,精度评估是检验提取结果准确性的关键环节。采用交并比(IoU),通过计算提取与真实边界交集和并集面积之比,直观反映两者重叠程度,IoU越接近1越吻合;Kappa系数综合考虑偶然一致性,全面评估分类精度;边界误差则通过计算对应点平均距离等量化提取与真实边界位置偏差。后处理与边界细化流程如图2所示。

2 实验与分析

2.1 实验设计与数据集

为验证本文方法的有效性,实验选取中国东部平原(江苏省)、西南山地(云南省)及东北黑土区(黑龙江省)三个典型农业区作为研究区域(表1),覆盖不同地形、气候条件和耕地类型。各区域数据集组成如下。

本次实验的硬件环境为NVIDIA IARTX3090GPU(拥有24GB显存)、Intel XeonE5-2678v3 CPU以及64GB内存;软件方面则采用了PyTorch1.10.0、GDAL3.4.1和OpenCV4.5.5。在模型训练参数设置上,U-Net编码器深度为5层,初始通道数64,

表 1 实验区域基本信息

区域名称	地理位置	面积(km ²)	地形特征	主要作物类型
江苏平原	118°E - 121°E, 32°N - 34°N	500	平坦、水网密集	水稻、小麦
云南山地	100°E - 102°E, 24°N - 26°N	300	丘陵、梯田	玉米、茶叶
黑龙江黑土区	125°E - 128°E, 45°N - 48°N	800	平缓、连片	大豆、玉米

表 2 数据集关键参数

数据类型	参数说明	来源/工具
Sentinel-2 影像	分辨率 10m(多光谱), 时间序列 5 - 10 月	ESA Copernicus
GF-2 影像	1m(全色)/4m(多光谱)	中国资源卫星应用中心
DEM 数据	30m 分辨率, 坡度精度 ±1°	NASA ASTER GDEM
土壤数据	12 类质地、有机质含量(g/kg)	HWSD v1.2
气象数据	日降水量(mm)、平均温度(°C)	中国气象局
标注数据	512×512 像素, 1200 张	人工标注

学习率设为 $1e-4$, 批量大小 8, 训练周期 100; DeepLabv3+ 选用主干网络 ResNet-101, ASPP 膨胀率为 [6, 12, 18], 学习率 $5e-5$, 批量大小 4。通用设置包含使用 Adam 优化器, 交叉熵与 Dice 损失按 1:1 权重搭配, 同时运用早停法(耐心值 10)。在多源融合与后处理参数上, Canny 边缘检测采用高斯核 $\sigma=1.5$, 低/高阈值比为 1:3; 形态学滤波选用 3×3 圆形核, 进行 1 次开运算与 1 次闭运算; 活动轮廓模型的迭代次数设为 100, 弹性系数 0.1, 梯度权重 0.5。

本次实验设计旨在全面评估所提方法的性能。实验选取传统阈值分割、随机森林以及单一 U-Net/DeepLabv3+ 模型作为对比方法, 同时通过区分黑龙江的平原连片耕地、云南的破碎梯田以及江苏的水田这三种不同地貌的耕地场景, 来

验证方法的普适性。为降低随机性影响, 确保实验结果的可靠性, 每组实验均重复 5 次并取均值。

2.2 实验结果与精度评估

通过实验, 利用本文提出的基于高分辨率遥感和多源数据融合的耕地边界精准提取方法, 对江苏、云南、黑龙江三个典型农业区的耕地边界进行提取, 提取结果如图 3 所示。

在图 3 中, (a) 江苏平原以浅色调集中连片区域体现平原水网密集区耕地的规整性, 少量深色调斑块代表非耕地地物; (b) 云南山地色调分布复杂, 浅色调区域呈碎片化与梯田状, 反映出山地丘陵地形下耕地的破碎特征, 不同色调交织展示出梯田边界的精细提取; (c) 黑龙江黑土区则以大片连续的浅色调区域显示平缓地形下的



(a) 江苏平原

(b) 云南山地

(c) 黑龙江黑土区

图 3 可视化结果




图4 实验结果

连片耕地,夹杂的少量深色调及其他色调斑块代表零星分布的非耕地。上述结果展示了本文方法在不同地貌(平原、山地、平缓黑土区)下对耕地边界的提取效果,验证了其在复杂场景中的适应性与精准性。

与传统阈值分割、随机森林以及单一的U-Net、DeepLabv3+模型的提取结果相比,本文方法提取的耕地边界更加连续、准确,能够更好地贴合实际耕地边界。实验结果如图4所示。

IoU(交并比):从“不同方法 IoU 对比”图可以看出,在江苏、云南、黑龙江三个区域,本文方法的IoU值均高于传统阈值分割、随机森林以及U-Net、DeepLabv3+模型。在江苏区域,本文方法IoU接近0.95,明显高于其他对比方法,表明本文方法提取的耕地边界与真实边界的重叠程度更高。

Kappa系数:在“不同方法 Kappa 对比”图中,本文方法在各区域的Kappa系数也处于领先地位,在黑龙江区域达到了0.85以上。Kappa系数综合考虑了偶然一致性,说明本文方法在耕地边界分类精度上更具优势。

边界误差:观察“边界误差对比”图可知,本文方法的平均误差在三个区域均为最低,在江苏区域平均误差接近1.5m。这表明本文方法提取的耕地边界与真实边界的位置偏差最小,准确性

更高。

将本文方法与传统阈值分割、随机森林以及单一的U-Net、DeepLabv3+模型进行对比。如图5所示,在IoU、Kappa系数等精度指标上,本文方法均显著优于传统方法。在边界误差方面,传统方法的误差普遍较高,如阈值分割方法在云南区域的边界平均误差超过8m,而本文方法能够有效降低误差,提升耕地边界提取的精度和可靠性。同时,对于不同地貌的耕地场景(如黑龙江的平原连片耕地、云南的破碎梯田以及江苏的水田),本文方法都展现出较好的适应性,而传统方法的性能波动较大,说明本文方法具有更好的普适性。

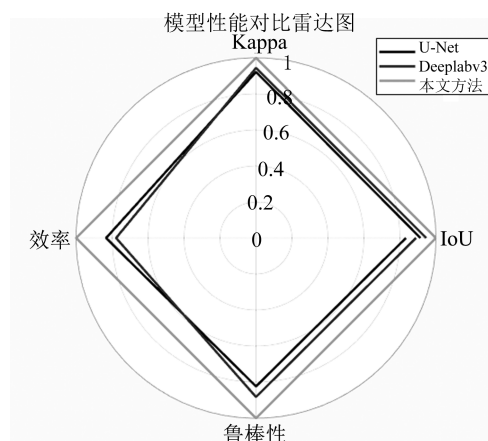


图5 模型性能对比结果

2.3 讨论与优化

2.3.1 方法在不同场景下的适用性分析

本文方法在不同地貌的耕地场景中展现出较好的适用性。在黑龙江的平原连片耕地场景下,由于地形相对平缓、耕地分布集中,本文方法借助多源数据融合与深度学习模型,能快速且准确地提取出大面积连续的耕地边界。对于云南的破碎梯田场景,尽管地形复杂、耕地分布零碎,但该方法仍能有效利用多源数据中地形、土壤等信息,结合深度学习对细节的捕捉能力,较为精准地提取出梯田的边界,相比传统方法优势明显。在江苏的水田场景中,水网密集的特点增加了边界提取的难度,而本文方法通过融合气象、土壤等多源数据,综合分析水田与周边地物的差异,同样实现了较为准确的边界提取。不过,在一些极端复杂的环境,如存在大量遮挡物或土地利用类型极其复杂的区域,该方法的精度可能会受到一定影响,仍有待进一步优化。

2.3.2 多源数据融合对边界提取精度的影响

多源数据融合显著提升了耕地边界提取的精度。地形数据中的数字高程模型(DEM)、坡度和坡向等信息,能帮助分析地形对耕地边界的限制和影响,尤其在山地、丘陵地区,可有效区分不同高程上的耕地与其他地物。土壤类型数据提供的土壤质地、肥力等信息,有助于从土壤特性角度区分耕地与非耕地,例如不同肥力的土壤在作物生长表现上的差异,可作为边界提取的参考依据。气象数据中的降水量、温度等气象因子,能够反映不同季节、气候条件下耕地的利用状态,辅助更准确地界定耕地边界。通过空间配准和特征融合将这些多源数据与高分辨率遥感影像相结合,使得边缘检测算法能够更充分地利用多方面信息,减少边界误判,提高提取精度。

2.3.3 深度学习模型与后处理算法的优化方向

深度学习模型方面,可进一步优化 U-Net 和 DeepLabv3+ 等模型的结构和参数。例如,尝试调整 U-Net 的网络深度和通道数,以更好地适应不同复杂度的影像数据;对于 DeepLabv3+,

探索更优的空洞卷积采样率组合,提升模型对多尺度特征的提取能力。同时,可以考虑引入更先进的注意力机制,增强模型对关键特征的关注,从而提高耕地区域分割的准确性。

后处理算法方面,在噪声去除和边界细化上仍有优化空间。中值滤波和高斯平滑算法在参数选择上较为依赖经验,未来可研究自适应的参数调整策略,根据影像的噪声水平和边界特征自动选择最优参数,以达到更好的平滑效果且不丢失重要细节。形态学细化算法可以结合更复杂的结构元素或改进腐蚀膨胀操作的顺序和次数,进一步提高边界细化的精度,使提取的耕地边界更加精准和清晰。

3 结论

本文提出基于高分辨率遥感和多源数据融合的耕地边界精准提取方法。通过在江苏、云南、黑龙江典型区域进行实验,结果表明,该方法在 IoU、Kappa 系数等指标上优于传统阈值分割、随机森林等方法,边界误差更小,对不同地貌耕地场景普适性好。同时,多源数据融合显著提升精度。但在极端复杂环境精度有待提高。该方法为耕地资源管理提供可靠支持,未来可从优化模型和算法方面进一步完善。

参考文献(References):

- [1] 李东辉, 孙肖, 霍润斌, 等. 地表基质遥感调查主要内容及方法探讨[J]. 黑龙江国土资源, 2025, 23(03): 44-51.
- [2] 韩俊. 不同的遥感解译方法在地表覆盖分类信息提取中的应用研究[D]. 昆明: 昆明理工大学, 2015.
- [3] 周林, 武黎黎, 李响. 基于改进 U-Net 的遥感影像农作物提取[J]. 计算机系统应用, 2025, 34(06): 89-96.
- [4] 乔志勇. 基于改进 DeepLabV3+ 的高分辨率遥感影像建筑物提取[J]. 地理空间信息, 2024, 22(12): 69-73.
- [5] Saralioglu E, Vatandaslar C. Land use/land cover classification with Landsat-8 and Landsat-9 satellite images: A comparative analysis between forest - and

- agriculture – dominated landscapes using different machine learning methods [J]. *Acta Geodaetica et Geophysica*, 2022, 57(04): 695–716.
- [6] Papadopoulou E, Mallinis G, Siachalou S, et al. Agricultural land cover mapping through two deep learning models in the framework of EU's CAP activities using sentinel-2 multitemporal imagery [J]. *Remote Sensing*, 2023, 15(19): 4657.
- [7] 席志龙. 主被动遥感协同的森林蓄积量反演及时空变化研究[D]. 哈尔滨: 东北林业大学, 2023.
- [8] Li Y, Chang C, Wang Z, et al. Identification of cultivated land quality grade using fused multi-source data and multi-temporal crop remote sensing information [J]. *Remote Sensing*, 2022, 14(09): 2109.
- [9] 朱曼, 方剑, 朱兆明, 等. 结合时序 Sentinel-2 和 GF-2 影像的耕地撂荒识别[J]. *测绘技术装备*, 2025, 27(01): 140–147.
- [10] 王飞文, 孙五斌, 郑明丹. 融合主成分分析与曲率特征的点云去噪方法研究[J]. *测绘与空间地理信息*, 2024, 47(11): 182–185.
- [11] 刘秀慧, 李勇, 葛莹, 等. 一种改进 U-Net 的干旱区地表水资源遥感提取研究[J]. *时空信息学报*, 2025, 32(02): 158–167.
- [12] 赵阳, 倪化勇, 伍剑波, 等. 基于 AHP-CF 模型的地质灾害易发性评价——以泰顺县仕阳镇为例[J]. *华东地质*, 2021, 42(01): 66–75.
- [13] 张俊, 陈雨艳, 秦震宇, 等. 改进 DeepLab v3+ 模型下的梯田遥感提取研究[J]. *智慧农业(中英文)*, 2024, 6(03): 46–57.
- [14] 郑茜, 邱春霞, 李存军, 等. 面向对象的无人机遥感影像亚田块边界提取[J]. *科技与创新*, 2022, 9(03): 1–3.
- [15] 王一帆, 徐涵秋. 基于客观阈值与随机森林 Gini 指标的水体遥感指数对比[J]. *遥感技术与应用*, 2020, 35(05): 1089–1098.
- [16] 宋梦龙, 颜涛, 张鹏, 等. 基于随机森林模型的不同空间分辨率遥感影像草地提取研究[J]. *草原与草业*, 2025, 37(01): 12–17.
- [17] 李雨阳, 刘舫, 胡文君, 等. 基于多源遥感数据的植被精细分类方法对比[J]. *世界地质*, 2025, 44(02): 311–321.
- [18] 戴佳乐. 高光谱遥感混合光谱特征分析与解混模型研究[D]. 唐山: 华北理工大学, 2023.
- [19] 张定源, 张景, 牛晓楠, 等. 空间冲突理论分析与实证研究[J]. *华东地质*, 2022, 43(01): 17–29.
- [20] 张定源, 张景, 牛晓楠, 等. 双评价理论探索与福建实践[J]. *华东地质*, 2021, 42(04): 419–428.
- [21] 单治彬, 孔金玲, 张永庭, 等. 面向对象的特色农作物种植遥感调查方法研究[J]. *地球信息科学学报*, 2018, 20(10): 1509–1519.

作者简介:

第一作者: 孙杰, 1994 年生, 男, 郑州人, 中国地质调查局地地球物理调查中心, 助理工程师, 主要研究方向为自然资源调查监测。Email: 513764364@qq.com;

通讯作者: 李玄辉, 1981 年生, 男, 河南周口人, 硕士, 中国地质调查局地地球物理调查中心, 高级工程师, 主要研究方向为自然资源调查监测。Email: 565783799@qq.com

Research on Precision Extraction Method of Cultivated Land Boundary based on High-Resolution Remote Sensing and Multi-Source Data Fusion

SUN Jie^{1,2}, RU Liang^{1,2}, LIANG Shuai^{1,2}, WU Shuai^{1,2}, LI Xuanhui^{1,2*}

(1. Center for Geophysical Survey, China Geological Survey, Langfang 065000, China

2. Technology Innovation Center for Earth Near Surface Detection, China Geological Survey, Langfang 065000, China)

Abstract: Precise extraction of cultivated land boundaries is a key technology in natural resource management and food security assessment. Considering the problem of insufficient accuracy of traditional methods in complex terrains, this study proposes a method for extracting cultivated land boundaries based on high-resolution remote sensing and multi-source data fusion. Data redundancy is eliminated through the joint dimension reduction of PCA/ICA, and the technical link of “deep learning preliminary segmentation-multi-source feature boundary optimization-morphological post-processing” is constructed to improve the boundary continuity and positioning accuracy in complex scenarios. The experiment selects the plain of Jiangsu, the mountainous area of Yunnan, and the black soil area of Heilongjiang for verification. The results show that after integrating multi-source data, the average IoU of the model reaches 0.92, which is 6.9%–9.5% higher than that of a single deep learning model. The boundary error decreases from 8.7 meters to less than 3.2 meters, and the Kappa coefficient exceeds 0.85, significantly superior to traditional methods, such as random forest and threshold segmentation. The multi-source data fusion framework and optimization technology constructed in the research provide an efficient solution for the dynamic monitoring of cultivated land.

Key words: high resolution remote sensing; multi-source data fusion; cultivated land boundary extraction