

基于遥感与 DeepLabV3 + 的丘陵山区耕地地块精准识别方法

陈聪¹ 任保鑫^{1,2} 王朕¹ 许政坤¹ 孙楠¹ 曹光乔¹

(1. 农业农村部南京农业机械化研究所, 南京 210014; 2. 贵州省农业科技信息研究所, 贵阳 550025)

摘要: 丘陵地区耕地细碎化问题, 阻碍了农业机械装备应用, 亟需在作业条件科学评估的基础上, 加快开展耕地的宜机化改造。以四川省广汉市为研究区域, 利用高分 6 号卫星 (GF-6) 的空间分辨率为 2 m 的遥感影像制作数据集, 基于 DeepLabV3 + 语义分割网络模型, 融合了空洞卷积技术, 采用 ResNet34 作为其骨干网络, 有效提取丘陵山区农田的尺寸、形态和方向等多尺度特征, 适应丘陵山区农田不规则边缘信息条件。开展了不同骨干网络、地物覆盖、地块面积等条件下的耕地提取及相关对比实验。研究结果表明, 采用 DeepLabV3 + 模型与 ResNet34 作为骨干网络的组合, 地块边界识别与实际值的吻合度较高, 精确率和召回率分别达到了 93% 和 86%; 样本区在作物全覆盖状态下, 地块识别准确率分别达到 71% 和 94%, 平均准确率为 82.5%。耕地分布离散程度对地块识别准确率无显著影响; 地块面积越大, 模型识别精度越高, 地块面积超过 100 m² 时, 识别精度提升至 80% 以上, 但地块面积小于 40 m² 时, 识别准确率不足 50%。

关键词: 丘陵山区; 地块识别; DeepLabV3 + ; 遥感影像

中图分类号: S29

文献标识码: A

文章编号: 1000-1298(2026)19-0318-07

OSID:



Precision Extraction of Cultivated Land Parcels in Hilly Areas Using Remote Sensing and DeepLabV3 +

Chen Cong¹ Ren Baoxin^{1,2} Wang Zhen¹ Xu Zhengkun¹ Sun Nan¹ Cao Guangqiao¹

(1. Nanjing Research Institute for Agricultural Mechanization, Ministry of Agriculture and Rural Affairs, Nanjing 210014, China

2. Guizhou Agricultural Science and Technology Information Institute, Guiyang 550025, China)

Abstract: The fragmented nature of farmland in hilly regions impedes the adoption of agricultural machinery, highlighting the urgent need for machine-accessible land transformation based on scientific operational assessments. Focusing on Guanghan, Sichuan as the study area, a dataset derived from GF-6 satellite imagery (2 m resolution) was utilized. The DeepLabV3 + semantic segmentation model, enhanced with dilated convolution and employing ResNet34 as its backbone network, effectively extracted multi-scale features, including size, shape, and orientation of hilly farmland, accommodating its irregular boundaries. Comparative experiments evaluated cropland extraction under varying backbone networks, land cover conditions, and plot sizes. Results demonstrated that the DeepLabV3 + /ResNet34 combination achieved high boundary alignment with actual values, yielding 93% precision and 86% recall. Under full crop coverage, plot identification accuracy reached 71% and 94% for specific metrics, averaging 82.5%. In the absence of crop coverage, the average accuracy was only 44.5%. The full crop coverage state can provide the model with rich spectral and textural information, which helped improve recognition accuracy. When cropped and non-cropped farmland were interspersed, the model's recognition accuracy was increased significantly, indicating that the boundary features of farmland under mixed coverage conditions were easier for the model to identify. Cropland dispersion showed no significant impact on accuracy, while larger plots correlated strongly with higher precision: accuracy exceeded 80% for plots more than 100 m² but dropped below 50% for those less than 40 m².

Key words: hilly area; land parcel extraction; DeepLabV3 + ; remote sensing images

收稿日期: 2025-06-06 修回日期: 2025-08-15

基金项目: 农业农村部科技项目、中国农业科学院基础科学研究中心科学任务项目 (CAAS-BRC-SAE-2025-02) 和南京市现代农机装备与技术创新示范项目 (NJ[2024]05)

作者简介: 陈聪 (1986—), 男, 副研究员, 博士, 主要从事农机作业信息感知与决策研究, E-mail: chenchong520206@163.com

通信作者: 曹光乔 (1978—), 男, 研究员, 博士, 主要从事农机化发展及系统优化研究, E-mail: caoguangqiao@126.com

0 引言

丘陵山区耕地识别是农田调查评估与宜机化改造的关键技术支撑。近年来,遥感技术作为主要手段在该领域发挥了重要作用,卫星遥感影像能够大范围高精度观测耕地特征,从而提高识别效率与精度^[1-2]。徐国良等^[3]基于多时相 Sentinel-1A 影像的研究表明,通过分析影像的后向散射系数变化,可以有效识别丘陵山区的耕地非粮化特征。与此同时,高分辨率遥感影像结合深度学习算法,如高分影像搭配卷积神经网络(CNN)和全卷积网络(FCN)等,能够实现对丘陵山区耕地的精准识别^[4]。这些深度学习算法通过自动提取耕地的纹理和形状特征,显著提升了识别效率和精度。此外,多源数据融合也成为提高识别精度的重要方法,通过结合光学影像、雷达影像和地形数据,能够充分利用不同数据源的优势,弥补单一数据源的不足^[5-6]。例如,联合波谱和地形特征的深度学习方法在梯田提取中表现出色,而结合高分辨率遥感影像和地理图像数据的智能计算方法,也能够有效识别丘陵山区的耕地^[7-8]。在应用方面,多个研究针对特定区域的丘陵山区耕地进行了识别与监测。李豪等^[9]对四川盆地丘陵区的耕地遥感识别研究表明,深度学习算法能够有效提取县域尺度的耕地分布,为区域土地资源管理提供了重要依据。在西南喀斯特山区,结合高分遥感影像和地理信息数据,实现了对石漠化耕地的精准提取^[10-11],为当地的土地利用规划提供了科学支持。此外,耕地非粮化识别也是当前研究的热点之一。基于遥感影像和深度学习算法的研究表明,通过分析影像的时间序列特征,能够有效识别丘陵山区耕地的非粮化现象^[12-14]。大量研究基于卫星遥感影像和深度学习技术开展耕地识别工作,但相关研究的重点多聚焦于区域性尺度的耕地识别。然而地块尺度的耕地信息是耕地改造、农机作业等不可或缺的数据支撑,尤其在人地矛盾突出的丘陵山区。因此,应从地块尺度开展丘陵山区耕地识别研究。

本文通过高分 6 号的遥感影像数据,获取研究区遥感影像并构建训练与测试数据集,基于 DeepLabV3 + 深度学习网络模型,采用 ResNet 作为骨干网络,融合多尺度预测策略与空洞卷积技术,开展地块尺度耕地信息识别方法研究,通过多种影像条件的对比实验,验证所提地块识别方法的适用性。

1 研究区概况与数据预处理

1.1 研究区概况

选取四川省广汉市(30°59'N,104°15'E)为研究

区,研究区地处成都平原东北部,龙泉山脉西麓,总面积 548.69 km²,该地区属亚热带湿润气候区,气候温和,四季分明,年降水量 890 mm,年平均气温 16.3℃。实验区具有良好的农业生产基础,县域内耕地分布广泛,耕地面积达 141.33 km²,其中 3.33 hm²以上的规模种粮面积超过 106.67 km²。研究区地物类型多样,耕地分布破碎分散,土地利用具有典型的丘陵地区特性,有利于检验深度学习模型在遥感地物识别方面的精度。

1.2 数据预处理

影像数据来源于高分 6 号卫星(GF-6)的空间分辨率为 2 m 的遥感影像,影像下载时间为 2022 年 5 月。使用 ENVI 5.3 软件的数据处理工具对影像数据进行辐射定标、大气校正、正射校正等预处理。

1.3 样本数据集制作

依据研究区域的地理环境、地形地貌特征以及土地利用类型,采用人工目视解译技术,获取构建模型所需的地物样本标签数据(Ground truth,GT),样本数据涵盖多种耕地类型。标签数据的裁剪重叠率被设定为 10%,并同时 对遥感影像和标签数据执行了滑动窗口裁剪操作,裁剪块的尺寸为 256 像素 × 256 像素,步幅为 128 像素 × 128 像素,最终获得 628 幅图像。通过水平翻转、垂直翻转、对角线镜像以及逆时针和顺时针旋转 90°等 5 种方式,对原始样本数据进行数据增强处理,共计生成 3 140 幅图像。通过随机抽样法将样本数据划分为训练集和测试集,其中训练集占 70%,测试集占 30%。

2 研究方法

2.1 硬件环境与训练参数设置

(1)硬件配置。本研究采用的计算设备具备 8 GB 的内存容量,搭载了型号为 Intel(R)Core(TM) i5-8250U CPU@1.60 GHz 的中央处理器,以及 4 GB 显存的 NVIDIA GeForce GTX 1050 显卡,以实现模型训练。

(2)训练参数配置。在本实验中,基于 PyTorch 框架构建并训练了 DeepLabV3 + 深度学习网络模型,并进行了参数调整。所采用的骨干网络为 ResNet,模型训练共进行了 150 个 epoch,每个批次的训练样本数量设定为 2。

2.2 耕地识别网络模型

采用的 DeepLabV3 + 语义分割网络模型,融合了空洞卷积技术,通过空洞空间金字塔池化模块,能够捕捉到不同尺度的上下文信息,从而更精确地提取丘陵山区农田的尺寸、形态和方向等多尺度特征^[15]。此外,该模型采用了编码器-解码器的结构,

整合了不同层次的特征,逐步重建空间信息,以获得更精确的分割对象掩膜,编码器部分主要由带有空洞卷积的深度卷积神经网络(DCNN)构成,可以强化丘陵山区农田不规则边缘信息。空洞空间金字塔

池化模块(ASPP)也采用了空洞卷积,可有效融合丘陵山区农田弱特征信息。ResNet 系列骨干模型,依据其模型架构的深度与宽度差异,可以有效适配丘陵山区复杂场景^[16]。模型网络结构如图 1 所示。




图 1 DeepLabV3 + 的网络结构图

Fig.1 Network structure diagram of DeepLabV3 +

2.3 识别精度评价指标

为了定量评价地块识别精度,采用基于混淆矩阵的分类精度定量评价方法,通过识别的精确率、召回率与 F1 分数 3 个指标综合评定地块识别精度。为了进一步衡量识别精度,用边界宽度来量化地块分割结果与真实边界之间的偏离程度。

3 结果分析

3.1 地块识别结果

在目标检测领域,DeepLabV3 + 实现了显著的技术突破,其核心之一在于采纳了 ResNet 作为其骨干网络架构。在 DeepLabV3 + 的框架下,ResNet 负责执行图像特征的提取任务,该网络融合了多尺度预测策略与空洞卷积技术,从而显著提升了目标检测的效能。基于 DeepLabV3 + 构建的耕地识别网络模型,采纳 ResNet 作为骨干模型,利用 1.3 节所述方法建立的数据集对模型分别进行训练与测试,得到研究区样本耕地的识别结果,识别效果如图 2 所示。深度学习网络能够有效地识别面状耕地范围,在耕地范围限定条件下,识别的地块尺度耕地边界均位于耕地内部,避免了对耕地外部地块边界的误识别,显著降低了提取过程中类似地块边界噪声的干扰,如道路边界或建筑边界。然而,地块尺度耕地边界提取结果受到耕地分布条件的影响,处理集中连片且光谱和纹理特征极为相似的地块边界时,识别效果欠佳。



图 2 耕地识别效果图

Fig.2 Farmland identification result

为探究模型的稳定性,开展了样本数量从 100 至 2 000 的对比实验,实验结果如表 1 所示。

表 1 样本数量与实验精度
Tab.1 Sample size and experimental accuracy %

参数	样本数量						
	100	300	500	800	1 300	1 500	2 000
精确率	13.2	16.4	30.6	40.1	90.4	93.1	93.0
召回率	12.3	15.2	27.8	38.1	84.3	86.0	86.1
F1 分数	13	16	29	39	87	89	89

结果表明当样本数量达到 1 300 时,模型识别精度显著提升,精确率、召回率与 F1 分数分别达到了 90.4%、84.3% 与 87%;当样本数量为 1 500 时,3 个精度指标分别达到 93.1%、86.0% 与 89%;而当样本数量增至 2 000 个时,模型识别精度较 1 500 样本量未见进一步提升,模型精度趋于稳定。

3.2 不同骨干模型识别精度

ResNet 系列骨干模型依据其网络架构的深度

与宽度差异,展现出不同的功能特性及适用场景。针对不同骨干网络在特定领域的适用性,选取了 ResNet34、ResNet50、ResNet101 共 3 种骨干模型进行了对比实验,得到评价结果如表 2 所示。

表 2 不同骨干模型耕地识别精度

Tab.2 Accuracy of arable land identification using different backbone models				%
骨干模型	精确率	召回率	F1 分数	
ResNet34	93	86	89	
ResNet50	90	86	88	
ResNet101	88	85	86	

采用 ResNet34 作为骨干网络的模型在实验中展现了更高的精度和更优的结果。其精确率为 93%,召回率为 86%,F1 分数为 89%,均超过 ResNet50 和 ResNet101 骨干模型。ResNet34 模型的高效性和准确性使得其在处理丘陵地区复杂地貌的

遥感影像数据时表现出色,特别是在资源受限和需要快速推理的应用场景下,其优势尤为明显。此外,ResNet34 模型的稳定性和鲁棒性也为后续的实验结果提供了有力保障,确保了地块提取的准确性和可靠性。

3.3 不同作物覆盖下识别精度

鉴于丘陵山区农业种植制度的复杂性,在同一地理区域内,同一时段内耕地状态可能存在种植状态与非种植状态并存的异质性情况,对耕地识别精度的一致性构成挑战。因此,根据样本影像特征,随机选取作物全覆盖、无作物覆盖、部分覆盖等 3 种类型的影像,每种类型的影像随机选择两个图幅,图幅大小完全一致。通过比较不同类型影像的实验结果,定量分析覆盖类型对识别精度的影响。按照 2.3 节所述测试方法开展实验结果,如图 3、表 3 所示。




图 3 不同作物覆盖度耕地提取效果

Fig.3 Extraction results of arable land under different crop coverages

表 3 不同覆盖状态耕地实验精度

Tab.3 Experimental accuracy of farmland under different coverage conditions						
参数	耕地类型					
	作物全	作物全	无作物	无作物	混合	混合
	覆盖 A	覆盖 B	覆盖 A	覆盖 B	耕地 A	耕地 B
标签数量	24	17	23	20	18	24
实验数量	17	16	10	9	8	22
准确率/%	71	94	44	45	45	91
边界宽度/m	0.21	0.23	0.70	0.74	0.36	0.26

研究区域耕地在作物全覆盖状态下,模型识别准确率分别达到 71% 和 94%,平均准确率为 82.5%。而在无作物覆盖状态下,准确率则为 44% 和 45%,平均准确率为 44.5%。当研究区域同时包含作物覆盖与无作物覆盖耕地时,准确率分别为 45% 和 91%,平均准确率为 68%。研

究结果表明,DeepLabV3 + 深度学习模型在作物覆盖耕地的边界提取方面具有较高的分辨能力,但在无作物覆盖耕地的边界识别方面效果不佳。这种现象的原因在于无作物覆盖耕地的界限与耕地颜色相似,从而影响了实验精度。对于混合耕地类型,准确率分别为 45% 和 91%,两者之间存在较大差异。尽管模型能够较为准确地区分作物覆盖与无作物覆盖耕地,但在同种覆盖状态的耕地连接时,其识别能力无法有效区分地块边界,导致模型识别精度进一步下降。然而,在混合耕地类型中,当同种类型耕地相连较少时,即作物覆盖与无覆盖耕地交叉分布时,模型的识别精度显著提高。

通过对比 3 种不同覆盖状态影像数据的实验结果,可以明确地看出,耕地覆盖状态对模型识别的准确性与精度具有显著影响。具体而言,当耕地处于

作物全覆盖状态时,识别效果和精度较高;反之,在耕地无作物种植状态下,识别结果则相对较差。为了探究实验结果差异的深层次原因,进一步计算对比了样本影像的归一化植被指数(NDVI),发现无作物覆盖耕地 NDVI 平均值为 0.1,田埂 NDVI 平均值为 0.11,非硬化道路 NDVI 平均值为 0.08。耕地地块、田埂与非硬化道路无明显的差异。由于丘陵山区高标准农田改造滞后,道路裸露,田埂狭小,部分地块之间甚至无田埂,无作物覆盖状态下耕地识别困难。




图 4 不同耕地占比提取效果对比图

Fig. 4 Comparison of extraction results for different proportions of cultivated land

表 4 不同耕地分布离散度实验精度

参数	耕地占比/%				
	100	80	70	60	40
标签数量	74	57	52	46	23
实验数量	61	48	48	40	20
准确率/%	82	84	92	86	87
边界宽度/m	0.36	0.33	0.27	0.31	0.32

如表 4 所示,在等面积条件下,耕地所占比例分别为 100%、80%、70%、60%、40% 时,相应的耕地识别准确率依次为 82%、84%、92%、86%、87%。排除耕地类型及其面积因素的干扰,准确率未表现出显著波动,平均分类准确率为 86.2%,边界宽度位于 0.32 m 左右,显示出相对稳定的性能。

经对比实验数据验证,DeepLabV3+ 深度学习模型在识别不同占比耕地状态时,展现出较高的稳定性,未出现显著波动。耕地分布的离散度并未对实验结果产生显著影响,构建的 DeepLabV3+ 深度学习模型,能够有效适用于丘陵山区分布不规则的耕地识别场景。

3.4 耕地分布离散度对识别精度的影响

丘陵山区耕地分布呈现显著的离散化特征,表现为少部分连片分布与大部分零散分布并存。为探究深度学习技术在耕地分布不均条件下的适用性,拟用耕地在图幅占比来表示耕地分布离散度,该指标可在 0~100% 之间取值。按耕地占整个图幅面积比例 100%、80%、70%、60%、40% 选取研究样本,并利用训练好的模型开展测试,验证分布离散度对精度的影响。按照 2.3 节所述测试方法,开展对比实验,结果如图 4、表 4 所示。

3.5 地块面积对识别精度的影响

丘陵山区地块普遍面积较小且差异较大。为了全面评估 DeepLabV3+ 深度学习模型在提取不同面积耕地时的性能表现,深入研究耕地规模与实验结果之间的相关性,在 ArcgisPro 地图中,设定比例尺为 1:7 000,分辨率为 128 像素×128 像素,图幅面积为 4 600 m²,选取平均耕地面积介于 32~182 m² 之间的图幅,每个图幅选择 26 个地块进行对比实验研究,以验证耕地面积对模型识别精度的影响。实验结果如表 5 所示。

表 5 不同耕地面积提取效果精度

参数	耕地面积/m ²							
	182	167	146	120	98	76	40	32
标签数量	26	26	26	26	26	26	26	26
实验数量	24	24	26	23	21	17	11	9
准确率/%	92	92	92	88	81	65	42	35
边界宽度/m	0.28	0.33	0.30	0.41	0.45	0.71	0.85	0.90

如表 5 所示,地块识别准确率随地块面积的减小而呈下降趋势。当耕地面积小于 40 m² 时,识别精

度低于 42%，边界宽度大于 0.85 m，尽管能够辨识出耕地的存在，但无法实现对地块边界的精准分割。当耕地面积超过 100 m²时，识别精度提升至 80% 以上，此时不仅能够准确识别耕地，还可以有效分割出地块边界，边界宽度小于 0.5 m。当耕地面积达到 146 m²时，识别精度达到峰值，边界宽度也小于 0.33 m，实现了对耕地的精确识别及不同耕地的精细分割。不难发现，当地块面积达到或超过 100 m²时，模型识别效果较为理想，能够精确地识别地块边界线并实现有效分割。然而，当耕地单位面积降至 40 m²以下时，边缘分割效果明显下降，尽管仍能准确识别出耕地区域，但耕地间的粘连性显著增强。因此，在应用 DeepLabV3 + 深度学习模型进行耕地提取时，需先评估其大致耕地面积，避免因耕地面积过小而导致识别效果较差。

4 讨论

4.1 不同深度学习模型在丘陵地区耕地提取中的适用性

基于 DeepLabV3 + 模型与 ResNet34 骨干网络的组合，在丘陵地区耕地识别任务中进行了有益探索，地块识别精确率达到 93%，召回率为 86%，略高于 Zhu 等^[17] 基于 DeepLabV3 + 模型开展的广西壮族自治区南宁市武鸣区的甘蔗田提取结果，表明本研究通过选择合适的骨干网络和数据增强方法，有效克服了丘陵地区复杂地形。此外，DeepLabV3 + 模型通过融合空洞卷积技术和多尺度预测策略，不仅能够准确识别耕地边界，还能有效捕捉耕地内部的语义信息，从而在整体识别精度上优于单纯的边缘检测模型^[18]。

4.2 耕地覆盖状态对深度学习模型精度的影响

在作物全覆盖状态下，模型的平均准确率可达 82.5%，而在无作物覆盖状态下，平均准确率仅为 44.5%。这一结果与其他相关研究的结论相呼应^[19]。在作物生长旺盛期，植被的光谱特征和纹理信息更为丰富，模型能够更准确地识别出耕地边界；而在无作物覆盖时，耕地与周围非耕地的光谱差异减小，导致模型识别精度下降。在混合覆盖状态下，当作物覆盖与无覆盖耕地交叉分布时，模型的识别精度显著提高。混合覆盖状态下的耕地边界在光谱和纹理上具有更明显的差异，为模型提供了更多的特征信息。表明深度学习模型在处理不同覆盖状态的耕地时，需要综合考虑光谱、纹理以及语义信息的融合，以提高模型的适应性和精度。

4.3 地块面积对深度学习模型识别精度的影响

通过实验发现，地块面积对 DeepLabV3 + 模型的识别精度有显著影响。当耕地面积超过 100 m²时，识别精度提升至 80% 以上，而当耕地面积小于 40 m²时，识别准确率不足 50%。小面积耕地的边界在遥感影像中往往较为模糊，且容易受到周围环境的干扰，导致模型难以准确识别。本文采用空洞卷积技术和多尺度预测策略，显著提高了模型对小面积耕地的识别能力。尽管如此，当耕地面积小于 40 m²时，模型的识别精度仍然较低。相比之下，部分传统的图像处理方法，如基于阈值分割和形态学操作的方法，在处理小面积耕地时可能具有一定的优势。因此，在实际应用中，可以考虑将深度学习模型与其他传统方法相结合，以提高对小面积耕地的识别精度。未来可以进一步探索引入更多的先验知识，提高模型对小地块的识别能力。

5 结论

(1) 采用 DeepLabV3 + 模型结合 ResNet34 骨干网络，在丘陵地区耕地提取任务中表现出色，地块边界识别与实际值的吻合度较高，精确率达到 93%，召回率达到 86%。DeepLabV3 + 模型在处理丘陵地区复杂地形和土地利用类型时具有显著优势，能够有效应对耕地分布破碎化的问题。

(2) 耕地的覆盖状态对模型的识别精度有显著影响，在作物全覆盖状态下，模型的平均准确率可达 82.5%，而在无作物覆盖状态下，平均准确率仅为 44.5%。作物全覆盖状态为模型提供了丰富的光谱和纹理信息，有助于提高识别精度。当作物覆盖与无覆盖耕地交叉分布时，模型的识别精度显著提高，表明混合覆盖状态下的耕地边界特征更易于被模型识别。

(3) 通过对比耕地在图幅占比的差异性分析，发现耕地分布的离散度对模型精度无显著差异，平均分类准确率为 86.2%。DeepLabV3 + 模型在处理丘陵地区分布不规则的耕地时具有较高的稳定性和适应性，能够有效应对耕地分布离散化的问题。

(4) 地块面积对模型的识别精度有显著影响，当耕地面积超过 100 m²时，识别精度提升至 80% 以上；而当耕地面积小于 40 m²时，识别准确率不足 50%。这表明，小面积耕地的边界在遥感影像中较为模糊，且容易受到周围环境的干扰，导致模型难以准确识别。因此，在实际应用中，对于小面积耕地的提取，可考虑结合其他传统方法，以提高识别精度。

参 考 文 献

[1] 陈昊,周光尧,王乾通,等. 基于一致性生成对抗的遥感多时相建筑物变化检测数据对生成技术[J]. 电子与信息学报, 2025,47(3):825–838.
Chen Hao,Zhou Guangyao,Wang Qiantong,et al. Building change detection data generation technology for multi-temporal remote sensing imagery based on consistent generative adversarial[J]. Journal of Electronics & Information Technology,2025,47(3): 825–838. (in Chinese)

[2] 赵成,梁盈盈,冯浩,等. 基于 Sentinel-2 遥感影像的黄土高原覆膜农田识别[J]. 农业机械学报,2023,54(8):180–192.
Zhao Cheng,Liang Yingying,Feng Hao,et al. Plastic-mulched farmland recognition in Loess Plateau based on Sentinel-2 remote-sensing images[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(8):180–192. (in Chinese)

[3] 徐国良,卢凌莹,杨璨,等. 基于多时相 Sentinel-1A 的丘陵山区耕地非粮化特征识别及驱动机制[J]. 农业工程学报, 2023,39(22):236–245.
Xu Guoliang,Lu Lingying,Yang Can,et al. Identification and driving mechanisms of non-grain cultivated land in hilly and mountainous areas based on multi-temporal Sentinel-1A images[J]. Transactions of CSAE,2023,39(22):236–245. (in Chinese)

[4] 余旭初,刘冰,薛志祥. 高光谱地物要素识别潜力分析与前景展望[J]. 测绘学报,2023,52(7):1115–1125.
Yu Xuchu,Liu Bing,Xue Zhixiang. Potential analysis and prospect of hyperspectral ground object recognition[J]. Acta Geodaetica et Cartographica Sinica,2023,52(7):1115–1125. (in Chinese)

[5] 李林超,钟良剑,苏庆,等. 基于多源数据融合的城市土地利用精细识别方法[J]. 西南交通大学学报,2025,60(2):326–335.
Li Linchao,Zhong Liangjian,Su Qing,et al. Fine urban land use identification based on fusion of multi-source data[J]. Journal of Southwest Jiaotong University,2025,60(2):326–335. (in Chinese)

[6] 刘晓敏,余梦君,乔振壮,等. 面向多源遥感数据分类的尺度自适应融合网络[J]. 电子与信息学报,2024,46(9):3693–3702.
Liu Xiaomin,Yu Mengjun,Qiao Zhenzhuang,et al. Scale adaptive fusion network for multimodal remote sensing data classification [J]. Journal of Electronics & Information Technology, 2024,46(9):3693–3702. (in Chinese)

[7] 谢君洋,林安琪,吴浩,等. 面向梯田遥感识别的 JAM-R-CNN 深度网络模型[J]. 遥感学报,2024,28(12):3136–3146.
Xie Junyang,Lin Anqi,Wu Hao,et al. JAM-R-CNN deep learning network model for remote sensing recognition of terraced fields[J]. National Remote Sensing Bulletin,2024,28(12):3136–3146. (in Chinese)

[8] Yu M,Rui X,Xie W,et al. Research on automatic identification method of terraces on the loess plateau based on deep transfer learning[J]. Remote Sensing,2022,14(10):2446.

[9] 李豪,杜雨秋,肖星竹,等. 基于深度学习的四川盆地丘陵区县域耕地遥感识别研究[J]. 智慧农业(中英文),2024, 6(3):34–45.
Li Hao,Du Yuqiu,Xiao Xingzhu,et al. Remote sensing identification method of cultivated land at hill county of Sichuan Basin based on deep learning[J]. Smart Agriculture,2024,6(3):34–45. (in Chinese)

[10] 唐荣彬,黄桂云,邱利文,等. 西南喀斯特不同生境石漠化程度划分方法研究[J]. 地球与环境,2023,51(4):441–454.
Tang Rongbin,Huang Guiyun,Qiu Liwen,et al. A new classification method of rocky desertification degree in different Karst habitats of Southwest China[J]. Earth and Environment,2023,51(4):441–454. (in Chinese)

[11] 陈艳英,徐彦平,杨琴,等. 基于 Landsat8 巫山石漠化区域监测识别方法探讨[J]. 气象科技进展,2021,11(2):76–81.
Chen Yanying,Xu Yanping,Yang Qin,et al. Discussion on monitoring and recognition method of Wushan rocky desertification area based on Landsat8[J]. Advances in Meteorological Science and Technology,2021,11(2):76–81. (in Chinese)

[12] 关小克,王秀丽,赵玉领. 黄河沿岸“非粮化”耕地形态特征识别与优化调控研究[J]. 农业机械学报,2021,52(10):233–242.
Guan Xiaoke,Wang Xiuli,Zhao Yuling. Morphological characteristics identification and optimization of “non-grain” cultivated land along Yellow River basin[J]. Transactions of the Chinese Society for Agricultural Machinery,2021,52(10):233–242. (in Chinese)

[13] Zhi J,Cao X,Liu W,et al. Remote sensing monitoring and spatial pattern analysis of non-grain production of cultivated land in Anhui Province, China[J]. Land,2023,12(8):1497.

[14] 谢花林,欧阳振益,陈倩茹. 耕地细碎化促进了耕地“非粮化”吗:基于福建丘陵山区农户的微观调查[J]. 中国土地科学,2022,36(1):47–56.
Xie Hualin,Ouyang Zhenyi,Chen Qianru. Does cultivated land fragmentation promote “non-grain” utilization of cultivated land: based on a micro survey of farmers in the hilly and mountainous areas of Fujian[J]. China Land Science,2022,36(1):47–56. (in Chinese)

[23] Victor N, Maddikunta P K R, Mary D R K, et al. Remote sensing for agriculture in the era of industry 5.0: a survey[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17: 5920 – 5945.

[24] Reedha R, Dericquebourg E, Canals R, et al. Transformer neural network for weed and crop classification of high resolution UAV images[J]. Remote Sensing, 2022, 14(3): 592.

[25] Wolfert S, Ge L, Verdouw C, et al. Big data in smart farming-a review[J]. Agricultural Systems, 2017, 153: 69 – 80.

[26] Kamilaris A, Kartakoullis A, Prenafeta-boldü F X. A review on the practice of big data analysis in agriculture[J]. Computers and Electronics in Agriculture, 2017, 143: 23 – 37.

[27] 姜京池, 闫莲, 刘劫. 基于精准知识筛选及知识协同生成的农业大语言模型[J]. 智慧农业(中英文), 2025, 7(1): 20 – 32.

Jiang Jingchi, Yan Lian, Liu Jie. Agricultural large language model based on precise knowledge retrieval and knowledge collaborative generation[J]. Smart Agriculture, 2025, 7(1): 20 – 32. (in Chinese)

[28] 刘珂艺. 基于大语言模型的小麦纹枯病防治知识图谱自动构建研究[D]. 北京: 中国农业科学院, 2024.

Liu Keyi. The research on the automatic construction of wheat sharp eyespot control knowledge graph based on large language models[D]. Beijing: Chinese Academy of Agricultural Sciences, 2024. (in Chinese)

[29] 张慧春, 田啟飞, 边黎明, 等. 基于多视角图像形态颜色纹理特征融合的生物量获取[J]. 农业机械学报, 2024, 55(10): 295 – 305.

Zhang Huichun, Tian Qifei, Bian Liming, et al. Plants biomass acquisition based on morphological, color and texture features of multi-view visible images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 295 – 305. (in Chinese)

[30] 梁秀英, 周风燃, 陈欢, 等. 基于运动恢复结构的玉米植株三维重建与性状提取[J]. 农业机械学报, 2020, 51(6): 209 – 219.

Liang Xiuying, Zhou Fengran, Chen Huan, et al. Three-dimensional maize plants reconstruction and traits extraction based on structure from motion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 209 – 219. (in Chinese)

[31] Jones J W, Hoogenboom G, Porter C H, et al. The DSSAT cropping system model[J]. European Journal of Agronomy, 2003, 18(3): 235 – 265.

[32] 清华大学. SuperBench[EB/OL]. (2024-12-31)[2025-07-24]. <https://fm.ai.tsinghua.edu.cn/superbench>.

(上接第 324 页)

[15] 武锦龙, 吴虹麒, 李浩, 等. 基于改进 DeepLabV3+ 的荞麦苗期无人机遥感图像分割识别方法研究[J]. 农业机械学报, 2024, 55(5): 186 – 195.

Wu Jinlong, Wu Hongqi, Li Hao, et al. Segmentation of buckwheat by UAV based on improved lightweight DeepLabV3+ at seedling stage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 186 – 195. (in Chinese)

[16] 杜小强, 李卓林, 马锟宏, 等. 基于空间注意力和可变形卷积的无人机田间障碍物检测[J]. 农业机械学报, 2023, 54(2): 275 – 283.

Du Xiaoqiang, Li Zhuolin, Ma Zhenghong, et al. UAV field obstacle detection based on spatial attention and deformable convolution[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 275 – 283. (in Chinese)

[17] Zhu M, Yao M, He Y, et al. Studies on high-resolution remote sensing sugarcane field extraction based on deep learning[J]. IOP Conference Series: Earth and Environmental Science, 2019, 237: 032046.

[18] Jiao S, Hu D, Shen Z, et al. Parcel-level mapping of horticultural crop orchards in complex mountain areas using vhr and time series images[J]. Remote Sensing, 2022, 14(9): 2015.

[19] Yang R, Ahmed Z U, Schulthess U C, et al. Detecting functional field units from satellite images in smallholder farming systems using a deep learning based computer vision approach: a case study from Bangladesh[J]. Remote Sensing Applications: Society and Environment, 2020, 20: 100413.

[20] Liu S, Liu L, Xu F, et al. A deep learning method for individual arable field (IAF) extraction with cross-domain adversarial capability[J]. Computers and Electronics in Agriculture, 2022, 203: 107473.