

基于星机协同与边界约束的夏玉米提取方法

曹培^{1,2} 赵豪雨¹ 韩文霆^{2,3}

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100; 2. 西北农林科技大学旱区农业节水研究院, 陕西杨凌 712100;
3. 旱区作物高效用水国家工程实验室, 陕西杨凌 712100)

摘要: 准确获取夏玉米种植区空间分布信息对农业资源监测、种植结构调查和农田精细化管理具有重要意义。针对 Sentinel-2 卫星影像在小地块农区田块边界处易受混合像元和邻近地物干扰、传统总体精度指标难以充分反映边界识别差异等问题,本文提出一种基于星机协同与边界约束的夏玉米提取方法。以 2025 年 7、8 月 Sentinel-2 双时相光谱-植被指数特征作为主体输入,每个时相包含 7 个原始波段和 7 个植被指数,共构成 28 通道卫星物候特征;同时利用无人机红边影像生成夏玉米软标签和田块边界先验,并设计边界感知门控融合模块(BAGF),将无人机提供的局部高分辨率空间结构信息定向注入田块边界和混合像元区域。在陕西省关中平原 9 个县区夏玉米样本上开展试验,并采用县区级空间分离方式划分训练集、验证集和测试集。结果表明,CS-FPNet+BAGF 在测试集上总体精度(OA)为 97.22%、交并比(IoU)为 95.23%、F1 值为 97.56%,优于 DeepLabV3+、FPN、PSPNet、SegFormer 和 U-Net 等模型。Trimap 边界分区评价结果表明,不同模型在田块内部区域均具有较高识别精度,性能差异主要集中在田块边界区域;本文方法 Boundary IoU(B-IoU)达 91.18%,边界-内部精度差(B-I Gap)降至 8.66%,较 SegFormer 和 U-Net 分别降低 2.98、3.40 个百分点。模型消融试验结果表明,FPN 多尺度解码器、无人机软标签和 BAGF 边界门控均能提高模型识别能力,其中显式边界门控较学习型门控在边界约束方面表现更稳定;输入消融试验结果表明,7—8 月双时相影像是夏玉米识别的主要信息来源,植被指数对总体分类精度具有小幅增益。研究结果表明,有限无人机影像可作为局部边界结构先验,与 Sentinel-2 双时相特征形成互补,从而提升复杂农区夏玉米种植区提取和田块边界识别精度。

关键词: 夏玉米提取; 无人机-卫星协同; 边界感知门控融合; Trimap 边界评价; Sentinel-2

中图分类号: S127

文献标识码: A

文章编号: 1000-1298(2026)20-0141-13

OSID:



Summer Maize Extraction Based on UAV-Satellite Collaboration and Boundary Constraints

Cao Pei^{1,2} Zhao Haoyu¹ Han Wenting^{2,3}

(1. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China
2. Institute of Water Saving Agriculture in Arid Regions, Northwest A&F University, Yangling, Shaanxi 712100, China
3. National Engineering Laboratory for Arid-region Crop High-efficiency Water Use, Yangling, Shaanxi 712100, China)

Abstract: Accurate acquisition of the spatial distribution of summer maize planting areas is important for agricultural resource monitoring, planting structure investigation, and refined farmland management. To address the problems that Sentinel-2 imagery is susceptible to mixed pixels and spectral interference from adjacent objects at field boundaries in smallholder agricultural areas, and that conventional overall accuracy metrics are insufficient to reflect differences in boundary recognition, a summer maize extraction method based on UAV-satellite collaboration and boundary constraints was proposed. In this method, Sentinel-2 dual-temporal spectral and vegetation-index features from July and August 2025 were used as the main input. Each temporal phase contained seven original spectral bands and seven vegetation indices, forming 28-channel satellite phenological features. Meanwhile, UAV red-edge imagery was used to generate summer maize soft labels and field boundary priors, and a boundary-aware gated fusion module, namely BAGF, was designed to directionally inject local high-resolution spatial structure

收稿日期: 2026-06-01 修回日期: 2026-07-04

基金项目: 国家自然科学基金青年项目(32301698)、陕西省重点研发计划项目(2024NC-ZDCYL-05-01)、陕西省“四链”融合项目(2025CY-JJQ-21)和云南省重点研发计划项目(202402AE090005)

作者简介: 曹培(1989—),女,副教授,博士,主要从事农情信息获取研究,E-mail: caopei2020@nwafu.edu.cn

information provided by UAV imagery into field boundary and mixed-pixel regions. Experiments were conducted by using summer maize samples from nine counties and districts in the Guanzhong Plain of Shaanxi Province, and a county-level spatially independent strategy was adopted to divide the training, validation, and test sets. The results showed that CS - FPNet + BAGF achieved an overall accuracy (OA) of 97.22%, an intersection over union (IoU) of 95.23%, and an F1 score of 97.56% on the test set, outperforming DeepLabV3+, FPN, PSPNet, SegFormer, and U-Net. The Trimap boundary partition evaluation showed that all models achieved relatively high recognition accuracy in field interior regions, while their performance differences were mainly concentrated in field boundary regions. The proposed method achieved a B - IoU of 91.18% and reduced the B - I Gap to 8.66%, which was 2.98 and 3.40 percentage points lower than those of SegFormer and U-Net, respectively. Model ablation experiments showed that the FPN multi-scale decoder, UAV soft labels, and BAGF boundary gating all improved the recognition ability of the model, and the explicit boundary gating mechanism was more stable than the learnable gating mechanism in boundary constraint. Input ablation experiments showed that the July - August dual-temporal imagery was the main information source for summer maize identification, while vegetation indices provided a slight gain in overall classification accuracy. The results indicated that limited UAV imagery could serve as a local boundary structure prior and complement Sentinel - 2 dual-temporal features, thereby improving summer maize planting area extraction and field boundary recognition accuracy in complex agricultural areas.

Key words: summer maize extraction; UAV - satellite collaboration; boundary-aware gated fusion; Trimap boundary evaluation; Sentinel - 2

0 引言

夏玉米是我国北方重要粮食作物类型之一,及时、准确获取夏玉米空间分布信息,对于粮食生产形势研判、农业资源管理、种植结构调整和农田精细化管理具有重要意义。遥感技术能在较大范围内连续获取地表覆盖信息^[1],其中 Sentinel - 2 影像兼具较高空间分辨率、较短重访周期和丰富光谱波段,已被广泛应用于作物识别、耕地提取和农业长势监测等任务^[2-4]。

近年来,深度学习语义分割模型在遥感地物分类中取得了较好效果^[5]。DeepLabV3+、FPN、PSPNet 和 U-Net 等网络能利用多尺度上下文信息进行像元级分类,在相对均质的农田内部区域通常可获得较高精度^[6]。然而,在关中平原等典型小农户种植区,田块尺度较小,农田与道路、村庄、果园和裸地等地物交错分布,10 m 分辨率卫星影像在田块边缘处易形成混合像元,导致模型在边界区域出现漏分、错分和边界外扩等问题。传统总体精度指标如总体精度(OA)、交并比(IoU)和 F1 值往往被大量田块内部像元主导,难以充分反映边界区域的识别差异。

无人机影像具有厘米级空间分辨率,能清晰表达田块边界、作物行纹理和地物空间结构,为卫星影像中边界混合像元识别提供了潜在补充^[7]。然而,无人机覆盖范围有限、采集成本较高,难以直接支撑区域尺度制图^[8-9]。因此,星机协同关键不应仅简

单拼接无人机和卫星数据,而应充分发挥二者优势:由卫星影像提供大范围、多时相物候信息,由无人机影像提供局部高精度空间结构先验,并通过模型设计将这种先验知识有效迁移到卫星影像分类过程。

针对 Sentinel - 2 卫星影像在夏玉米田块边界处易受混合像元和邻近地物干扰、无人机影像难以直接支撑大范围制图以及传统总体精度指标难以反映边界区域识别差异等问题,本文提出一种融合无人机边界先验的卫星影像夏玉米提取方法。构建面向夏玉米提取的无人机-卫星跨尺度协同框架,利用 Sentinel - 2 双时相影像表征夏玉米关键生育阶段的光谱-物候变化,并引入无人机高分辨率影像提供局部田块边界和作物覆盖先验。设计边界感知门控融合模块 BAGF,将无人机软标签作为作物覆盖信息来源,将边界先验作为空间门控约束,使无人机信息主要作用于田块边界和混合像元区域,从而改善边界处的误分问题。采用 Trimap 边界分区评价方法,从田块内部、边界和外部区域分别评价模型表现,进一步揭示不同模型在边界区域的识别差异,以期为夏玉米种植区提取和农田边界精细识别提供方法参考。

1 研究区与数据来源

1.1 研究区概况

研究区位于陕西省关中平原,覆盖陈仓、富平、临潼、临渭、渭城、凤翔、乾县、蒲城和三原 9 个县区,每个县区包含 2 个采样区,县区分布点和无人机采

样区分布如图 1 所示。关中平原是陕西省重要粮食生产区,夏玉米种植较为集中,但区域内田块破碎、道路和村庄密集,果园、设施农业和裸地等地物与农田交错分布,具有典型的复杂农业景观特征。该区域为检验无人机-卫星协同方法在小地块边界识别中的有效性提供了较为适宜的试验条件。




图 1 关中平原研究区及无人机采样区分布
Fig. 1 Distribution of study area and UAV sampling areas in Guanzhong Plain

1.2 Sentinel-2 卫星影像数据处理

采用欧洲空间局 (European Space Agency, ESA) 发布的 Sentinel-2A/B 多光谱卫星影像作为主要遥感数据源。Sentinel-2 搭载的多光谱成像仪 (Multispectral instrument, MSI) 共包含 13 个光谱波段。结合夏玉米生长阶段的光谱响应特征及不同波段对植被长势、叶绿素含量、水分状态和冠层结构的表征能力^[10-11],选取 B2 (蓝光)、B3 (绿光)、B4 (红光)、B5 (红边)、B8 (近红外)、B11 (短波红外 1) 和 B12 (短波红外 2) 共 7 个原始波段作为基础光谱变量。

在 Google Earth Engine 平台完成影像获取与预处理。分别选取 2025 年 7、8 月 Sentinel-2 Level-2A 地表反射率产品构建双时相输入数据。本文目标为夏玉米种植区空间提取,而非完整生育期动态监测。因此,时相选择重点是获取夏玉米与非目标地物差异明显、田块空间形态较稳定的关键识别窗口。关中平原 7—8 月夏玉米处于旺盛生长、抽雄吐丝至灌浆阶段,冠层覆盖、红边响应、近红外反射和田块边界特征较明显,能够支撑夏玉米种植区提取。需要说明的是,夏玉米抽雄、吐丝和灌浆等生育进程并非严格按照自然月离散分布,不同县区受播期、品种、灌溉条件和田间管理方式影响会存在一定时间差异。因此,采用 7 月和 8 月月尺度中值合成影像,并不将 2 个时相与具体生育期一一对应,而是作为夏玉米关键生长阶段连续变化过程的代表观测。其中,7 月影像主要反映夏玉米旺盛生长期的高植被覆盖和较强光合作用状态,8 月影像主要反映抽雄吐丝至灌浆阶段的冠层结构变化、水分响应和生理

状态差异。双时相影像能够从时序变化角度增强夏玉米与裸地、道路、村庄、果园及其他作物之间的可分性。

为降低云、薄雾、云影及局部异常观测的影响,基于 Sentinel-2 Level-2A 产品质量信息进行云和云影剔除,并在月尺度内对可用观测进行中值合成,分别生成 2025 年 7、8 月代表性影像。其中,7 月和 8 月合成影像分别以 2025 年 7 月 6 日和 2025 年 8 月 12 日的有效观测为主要参考。针对不同波段空间分辨率不一致问题,将 B5、B11 和 B12 等 20 m 波段重采样至 10 m,使所有输入波段保持一致空间尺度。随后,对研究区影像进行裁剪、空间配准和边界一致性检查,确保不同月份、不同波段及标签数据在空间位置上严格对应。

在特征构建方面,除 7 个原始波段外,进一步计算 7 个常用植被指数 (表 1)。上述指数分别从植被覆盖度、冠层活力、叶绿素变化、土壤背景影响和水分响应等角度补充表征夏玉米关键生长阶段的光谱特征,为后续模型识别提供多维特征信息^[12-15]。

表 1 植被指数及计算公式

指数	计算公式
归一化植被指数 (NDVI)	$NDVI = (B_8 - B_4) / (B_8 + B_4)$
二波段增强植被指数 (EVI2)	$EVI_2 = 2.5(B_8 - B_4) / (B_8 + 2.4B_4 + 1)$
土壤调节植被指数 (SAVI)	$SAVI = (1 + L)(B_8 - B_4) / (B_8 + B_4 + L)$
绿光归一化植被指数 (GNDVI)	$GNDVI = (B_8 - B_3) / (B_8 + B_3)$
红边归一化植被指数 (NDRE)	$NDRE = (B_8 - B_5) / (B_8 + B_5)$
地表水分指数 (LSWI)	$LSWI = (B_8 - B_{11}) / (B_8 + B_{11})$
归一化水体指数 (NDWI)	$NDWI = (B_3 - B_8) / (B_3 + B_8)$

注: B_3 、 B_4 、 B_5 、 B_8 和 B_{11} 分别表示 Sentinel-2 绿光、红光、红边、近红外、短波红外 1 波段的地表反射率;SAVI 中 L 为土壤调节因子,取 0.5;公式计算前各波段均完成空间重采样、云掩膜和归一化处理。

1.3 无人机影像数据处理

无人机影像采集时间为 2025 年 8 月 18—20 日,覆盖陕西省关中平原陈仓、凤翔、富平、蒲城、乾县和三原 6 个县区,共获取 10 组无人机多光谱影像,部分无人机采样区玉米长势如图 2 所示,覆盖总面积为 2.145 1 km²,各县区影像数量和覆盖面积见表 2。采集平台为大疆御 3 型多光谱无人机,飞行高度设置为 80 m,航向重叠率和旁向重叠率均为 80%。受外业期间天气、光照条件、飞行安全及作业时间等因素限制,无人机航拍未能覆盖全部 9 个样本县区,其数据主要用于生成局部软标签和边界先验,而非作为全区域连续制图输入。




图2 无人机采样区夏玉米长势实景

Fig. 2 Field views of summer maize growth in UAV sampling areas

表 2 无人机影像数量及覆盖面积

Tab. 2 UAV image number and coverage area		
县区	影像数量	面积/km ²
陈仓	2	0.398 8
凤翔	2	0.435 2
富平	1	0.201 3
蒲城	2	0.515 4
乾县	1	0.168 1
三原	2	0.426 3
合计	10	2.145 1

主要选取无人机红边波段影像生成夏玉米软标签和田块边界先验。红边波段位于红光与近红外波段之间,对作物叶绿素含量、冠层结构和植被生长活力变化较为敏感,能较好反映夏玉米冠层与裸地、道路、田埂等非植被地物之间的光谱差异^[16-18]。同时,Sentinel-2 输入特征中包含红边波段(B5)及NDRE 等红边相关指数,采用无人机红边影像构建先验信息,有助于增强星机数据在光谱语义上一致性。需要说明的是,本文并不是将单一红边波段作为独立分类依据,而是作为训练阶段的局部高分辨率空间结构先验,与 Sentinel-2 双时相物候特征共同参与模型训练。

无人机影像采集过程进行了辐射定标处理,通过标准反射率校准板和机载光照传感器对原始影像进行反射率校正,以减弱不同采集时段光照条件差异对影像的影响。影像预处理和正射拼接由 Pix4Dmapper 软件完成,主要包括影像质量检查、特征点匹配、空三加密、正射校正和影像镶嵌等步骤,最终生成 GeoTIFF 格式的无人机正射影像。

为保证无人机影像与 Sentinel-2 卫星影像在空间位置上一致性,将无人机正射影像统一转换至

与 Sentinel-2 数据一致的投影坐标系,并结合道路交叉口、田块边缘等稳定地物进行配准检查。完成配准后,并非将厘米级无人机原始影像简单重采样至 10 m 后作为普通光谱通道直接输入模型,而是在无人机原始分辨率下提取夏玉米覆盖信息和田块边界结构信息,再聚合至 Sentinel-2 10 m 网格,分别生成夏玉米软标签 U_{soft} 和田块边界先验 U_{bound} 。其中, U_{soft} 用于表征 10 m 像元内部由高分辨率无人机影像统计得到的夏玉米覆盖比例,可反映混合像元内作物覆盖程度; U_{bound} 用于表征 10 m 像元内田块边界、田埂及道路-农田交界等空间结构信息,可指示田块边缘和混合像元区域。因此,无人机高分辨率信息在聚合至 10 m 网格后,仍以子像元作物覆盖比例和边界结构比例形式保留,并在后续 BAGF 模块中作为局部空间先验参与特征融合。

从时间尺度看,Sentinel-2 双时相影像用于表征夏玉米 7—8 月关键生育阶段的光谱-物候变化;无人机影像集中采集于 2025 年 8 月 18—20 日,主要用于提供夏玉米生长中后期较为稳定的冠层覆盖、田块边界和混合像元空间结构信息。由于夏玉米田块边界、田埂及道路-农田交界等空间结构在 7—8 月生长季内相对稳定,8 月无人机影像虽未覆盖整个 7—8 月时段,但可作为 Sentinel-2 10 m 像元尺度下高分辨率空间先验。本文并不是利用无人机影像替代 Sentinel-2 进行时序物候建模,而是作为训练阶段和局部边界精化阶段的空间结构约束,与 Sentinel-2 双时相物候特征形成互补。

1.4 标签数据制作

以 2025 年 7、8 月 Sentinel-2 双时相影像为基础,构建空间分辨率为 10 m 的夏玉米/非夏玉米二分类标签。单个原始样本块尺寸为 1 024 像元 ×

1 024 像元,对应地面范围约为 10.24 km × 10.24 km,单个 Patch 覆盖面积约为 104.86 km²。外业调查于 2025 年 8 月 18—20 日开展,对应关中平原夏玉米抽雄吐丝至灌浆阶段。该时期夏玉米植株高度、冠层覆盖度和田块边界形态较为明显,适合开展样点核查和遥感判读结果复核。调查过程中,每个采样区记录约 20 个相对均匀分布的核查点,覆盖夏玉米田块及典型非夏玉米地物;18 个采样区共形成约 360 个采样区内核查点,平均调查密度约为 0.19 个/km²。同时,在前往各采样区及无人机作业区过程,同步记录夏玉米集中种植区、典型非玉米地物和田块边界区域的空间位置及现场图像,形成补充观测记录。

标签制作过程,综合利用 Sentinel-2 双时相影像、无人机正射影像、外业图像、样点记录及高分辨率参考影像进行目视解译与空间校核。对于无人机覆盖区域,利用厘米级正射影像辅助判定夏玉米田块边界、田埂位置及像元内部作物覆盖情况;对于无人机未覆盖区域,则结合 Sentinel-2 光谱-植被指数特征、外业调查记录和高分辨率参考影像进行综合判读^[19]。为进一步说明地面标签数量构成,统计训练集、验证集和测试集中夏玉米与非夏玉米 2 类标签像元数量、面积及比例,结果见表 3。需要说明的是,表中非夏玉米类别为二分类任务中背景类,其内部不同地物类型未进行独立类别标注。因此,不对道路、果园、其他作物等二级地物分别计算分类精度,而是在误差分析中结合外业记录、无人机影像和高分辨率参考影像对主要易混来源进行讨论。

表 3 夏玉米/非夏玉米二分类标签数量
Tab.3 Binary labels for summer maize and non-summer maize

数据集	夏玉米面 积/km ²	非夏玉米 面积/km ²	夏玉米占 比/%	比例
训练集	334.0	714.6	31.8	1:2.1
验证集	93.7	116.0	44.7	1:1.2
测试集	117.2	92.5	55.9	1:0.8
合计	544.9	923.1		

1.5 训练数据集划分

为降低空间邻近样本带来的自相关影响,采用县区级空间分离方式划分训练集、验证集和测试集,确保不同数据集在县区 and 原始 Patch 层面保持空间独立,划分结果见表 4。为适配深度学习网络输入,在完成数据集划分后,将原始 1 024 像元 × 1 024 像元 Patch 裁剪为 256 像元 × 256 像元 Tile;其中训练集采用 stride 为 64 像元的滑窗裁剪方式以增加训练样本数量和边界样本覆盖度,验证集和测试集保

持独立区域评价。需要强调的是,Tile 仅作为模型训练与推理的输入单元,真正的空间独立单位仍为县区和原始 Patch。

表 4 数据集划分与 Tile 数量
Tab.4 Dataset partitioning and Tile statistics

数据集	县区	Patch 数量	裁剪参数/ 像元	Tile 数量
训练集	陈仓、富平、临潼、临渭、渭城	10	256 × 256, stride 为 64	1 690
验证集	凤翔、乾县	2	256 × 256, stride 为 64	338
测试集	蒲城、三原县	2	256 × 256, stride 为 64	338

2 研究方法

2.1 总体技术路线

总体技术路线如图 3 所示,主要包括 Sentinel-2 双时相物候特征构建、无人机软标签与边界先验生成、CS-FPNet 跨尺度协同建模、BAGF 边界感知门控融合以及夏玉米空间分布输出 5 个环节。Sentinel-2 影像提供大范围双时相光谱和植被指数特征,用于表征夏玉米关键生育阶段的光谱-物候变化;无人机影像提供局部高分辨率作物覆盖和田块边界结构信息,用于构建训练阶段的空间先验约束。

从应用方式看,本文方法包括区域尺度初步制图和局部边界精化 2 种模式。在区域尺度制图中,可仅依赖 Sentinel-2 双时相输入完成夏玉米初步提取;在无人机覆盖的重点样区或边界复杂区域,则进一步利用无人机影像生成 U_{soft} 和 U_{bound} ,并通过 BAGF 模块进行边界精化。因此,本文方法并不要求无人机影像连续覆盖整个研究区,而是利用有限无人机样本为卫星模型提供局部高分辨率空间结构先验。

2.2 Sentinel-2 双时相物候特征构建

选择 2025 年 7、8 月 Sentinel-2 影像构建双时相物候特征,主要依据夏玉米种植区提取任务对关键识别窗口的需求。对于夏玉米空间分布提取,模型需捕捉目标作物与非目标地物之间稳定且具有判别性的光谱-物候差异,而非完整描述作物全生育期变化。关中平原夏玉米 7—8 月通常已形成较高冠层覆盖,并进入旺盛生长、抽雄吐丝至灌浆阶段,红边、近红外及水分相关特征较为突出,田块边界和作物覆盖形态也相对稳定。因此,7—8 月双时相影像能较好表征夏玉米由快速生长到冠层稳定阶段的关键变化过程,为夏玉米与裸地、道路、村庄、果园及其他作物的区分提供有效特征。将 2 个时期的 14 通道特征进行堆叠,形成 28 通道输入,使模型能利用




图3 总体技术路线

Fig. 3 Overall technical workflow

夏玉米关键生育阶段的光谱-物候变化进行识别^[20-22]。

设第 t 个时相 Sentinel-2 输入特征为 X_t ,其中 $t \in \{7, 8\}$ 。每个时相包含 7 个原始波段和 7 个植被指数,共 14 个通道,可表示为

$$X_t = \{B_2, B_3, B_4, B_5, B_8, B_{11}, B_{12},$$

$$NDVI, EVI_2, SAVI, GNDVI, NDRE, LSWI, NDWI\}_t$$

将 2025 年 7、8 月 2 个时相特征按通道维度进行堆叠,形成 Sentinel-2 双时相输入特征,即

$$X_{S2} = \text{Concat}(X_7, X_8)$$

式中 X_{S2} ——模型输入的 Sentinel-2 双时相特征,共包含 28 个通道

由于部分植被指数由原始波段计算得到,28 通道输入特征间不可避免存在一定相关性。采用上述组合特征的目的并非进行线性回归意义下独立变量解释,而是为深度语义分割模型提供多角度的光谱、红边、水分和物候变化信息。深度卷积网络可通过卷积权重学习、归一化、非线性映射和多尺度特征选择,在训练过程自适应利用有效特征并抑制冗余信息。为降低特征冗余和过拟合风险,对各通道进行归一化处理,并在训练过程采用通道 dropout、数据增强、权重衰减和早停策略。

2.3 无人机软标签与边界先验生成

无人机影像具有厘米级空间分辨率,能清晰表达田块边界、田埂、道路-农田交界及作物冠层细节。

为将该高分辨率空间信息引入 Sentinel-2 10 m 像元尺度建模,基于无人机红边正射影像生成夏玉米软标签 U_{soft} 和田块边界先验 U_{bound} 。

首先,对无人机红边反射率影像进行百分位归一化,降低极端亮度值对聚合的影响。设归一化后无人机红边影像为 R_{re} ,第 i 个 Sentinel-2 像元对应的无人机像元集合为 Ω_i ,则软标签可表示为

$$U_{soft}(i) = \frac{1}{|\Omega_i|} \sum_{p \in \Omega_i} R_{re}(p) \tag{1}$$

式中 $U_{soft}(i)$ ——第 i 个 Sentinel-2 10 m 像元内夏玉米覆盖比例或作物存在概率的软约束,取 $[0, 1]$

与二值硬标签相比,软标签能更细致地表达田块边缘区域的混合像元状态。

其次,基于无人机原始分辨率影像提取边缘信息,并将边缘结果重采样至 Sentinel-2 10 m 网格,生成边界先验 U_{bound} ,可表示为

$$U_{bound} = \text{Resize}(E(R_{re})) \tag{2}$$

式中 $E(\cdot)$ ——Canny 边缘检测算子^[23]

$\text{Resize}(\cdot)$ ——尺度聚合与重采样操作

与 U_{soft} 强调像元内部作物覆盖概率不同, U_{bound} 主要用于指示田块边缘、道路-农田交界和混合像元区域。在 BAGF 模块中, U_{bound} 作为门控权重,用于控制无人机先验信息的注入位置。

Sentinel-2 双时相影像和无人机影像在时间和

空间尺度上存在差异。Sentinel-2 影像主要用于表征夏玉米关键生育阶段的区域尺度光谱-物候变化; 无人机影像主要用于提供夏玉米生长中后期较为稳定的田块边界和冠层覆盖结构。采用“先高分辨率提取、后 10 m 网格聚合”方式实现跨尺度融合, 即在无人机原始空间分辨率下提取作物覆盖和边界信息, 再与 Sentinel-2 10 m 网格对齐生成先验变量, 而非直接对无人机影像进行简单降采样拼接。

2.4 CS-FPNet 网络结构

CS-FPNet 网络结构如图 4 所示, 主要由 Sentinel-2 物候特征提取分支、无人机先验注入分支、BAGF 边界感知门控融合模块和 FPN 解码器组成^[24-25]。Sentinel-2 分支以双时相 28 通道特征 X_{s2} 作为输入, 通过 4 阶段卷积特征提取结构生成多尺度特征金字塔, 计算式为

$$\{f_1, f_2, f_3, f_4\} = F_{s2}(X_{s2}) \quad (3)$$

式中 f_s ——第 s 个尺度的 Sentinel-2 特征, $s = 1, 2, 3, 4$

$F_{s2}(\cdot)$ ——卫星影像特征提取分支

不同尺度特征分别用于表征夏玉米局部纹理、地块结构和上下文信息。

无人机边界先验分支以夏玉米软标签 U_{soft} 和田块边界先验 U_{bound} 作为输入, 为 BAGF 模块提供局部高分辨率空间先验。BAGF 模块在不同尺度上将无人机先验定向融合至 Sentinel-2 特征中, 得到增强后的多尺度特征 F'_s 。最后, FPN 解码器对增强后的多尺度特征进行自顶向下融合, 并输出夏玉米二分类预测结果, 即

$$\hat{Y} = D_{FPN}(F'_1, F'_2, F'_3, F'_4) \quad (4)$$

式中 $D_{FPN}(\cdot)$ ——FPN 解码器

$\hat{Y}$ ——模型输出的夏玉米预测结果




图 4 CS-FPNet 总体结构

Fig. 4 Overall architecture of CS-FPNet

2.5 边界感知门控融合模块 (BAGF)

BAGF 是本文网络的核心模块, 目的是避免无人机信息被无差别地注入整幅卫星影像, 而是使其重点作用于田块边界和混合像元区域。该模块的基本思想为: U_{soft} 表示注入什么信息, 即像元内部夏玉米覆盖概率; U_{bound} 表示在哪里注入信息, 即边界和混合像元位置; 可学习参数 α_s 表示“注入多少信息”, 即不同尺度上无人机先验对卫星特征的影响强度。

对于第 s 个尺度的 Sentinel-2 特征 f_s , BAGF 融合过程可表示为

$$f_s^* = f_s + \alpha_s g_s \odot u_s \quad (5)$$

$$u_s = F_{UAV}^s(U_{soft}, U_{bound}) \quad (6)$$

$$g_s = \text{Resize}_s(U_{bound}) \quad (7)$$

式中 g_s ——与第 s 个尺度特征尺寸一致的边界门控图

$\text{Resize}_s(\cdot)$ ——尺度匹配操作

$\odot$ ——逐元素相乘

f_s^* ——融合后增强特征

F_{UAV}^s ——第 s 个尺度上无人机先验特征编码函数

其中, u_s 并不是原始无人机影像, 而是由 U_{soft} 和 U_{bound} 经轻量级卷积编码后得到的多尺度无人机先验特征。 U_{soft} 提供 10 m 像元内部的夏玉米覆盖概率信息, U_{bound} 提供田块边界和混合像元位置约束, 二者经编码后形成与 Sentinel-2 分支特征尺寸和通道数一致的 u_s 。随后, BAGF 利用 g_s 对 u_s 进行边界位置约束, 使无人机先验主要作用于田块边界和混合像元区域, 而不是在所有像元上无差别注入。

该设计具有 2 方面作用: ①在田块边界和混合像元区域, g_s 具有较高响应, 能够引导无人机先验特征参与卫星特征修正, 从而缓解 Sentinel-2 10 m 像元中作物与非作物地物混合导致的错分。②在田块内部区域, g_s 响应较低, 模型主要保留 Sentinel-2 物候特征的主导作用, 减少无差别融合可能带来的噪声干扰。因此, BAGF 更符合田块内部依赖卫星物候信息、边界区域引入无人机结构先验的建模逻辑。

2.6 Trimap 边界分区评价方法

传统 OA、IoU 和 F1 值等总体指标易受到大量田块内部像素影响,难以充分反映模型在田块边界混合像素区域的表现。为此,采用 Trimap 边界分区评价方法,将评价区域划分为 Exterior、Boundary 和 Interior 3 类区域,并分别计算模型在不同区域内的识别精度^[26]。其中,Boundary 表示距离田块边界较近的混合像素区域,Interior 表示远离边界的夏玉米田块内部区域,Exterior 表示远离夏玉米田块的外部区域。

设真实标签为 Y ,边界宽度为 w ,形态学膨胀和腐蚀操作分别表示为 $Dilate(\cdot)$ 和 $Erode(\cdot)$ 。则 3 类区域可定义为

$$Boundary = Dilate(Y, w) - Erode(Y, w) \quad (8)$$

$$Interior = Erode(Y, w) \quad (9)$$

$$Exterior = 1 - Dilate(Y, w) \quad (10)$$

在各区域内分别计算 IoU、F1 值等指标,以分析模型在田块内部、边界和外部区域的性能差异。

同时,为量化模型在田块边界处的精度损失,定义边界-内部精度差 (B-I Gap) 为

$$L_{B-I\,Gap} = IoU_{Interior} - IoU_{Boundary} \quad (11)$$

式中 $IoU_{Interior}$ 、 $IoU_{Boundary}$ ——田块内部区域和边界区域 IoU

B-I Gap 越小,说明模型在边界区域相对于田块内部的性能损失越小,边界保持能力越强。通过该指标,可以更直观地评价无人机边界先验和 BAGF 模块对田块边界混合像素识别的改进效果。

3 试验设计

3.1 对比模型设置

为验证 CS-FPNet 在夏玉米种植区提取和田块边界识别中的有效性,选取 DeepLabV3+、FPN、PSPNet、SegFormer 和 U-Net 作为对比模型。其中,FPN 代表特征金字塔融合方法;PSPNet 通过空间金字塔池化结构增强全局语义表达^[27];DeepLabV3+ 代表基于空洞卷积的多尺度上下文建模方法^[28];SegFormer 为代表性层次化 Transformer 语义分割模型;U-Net 为经典编码-解码结构模型。通过与上述模型进行对比,可综合评价本文方法在总体分类精度、边界保持能力和混合像素识别方面的性能。

为保证试验公平性,所有模型均采用相同的 Sentinel-2 双时相 28 通道输入、相同训练/验证/测试划分、相同 Tile 裁剪方式和数据增强策略。所有模型采用 AdamW 优化器进行训练,初始学习率设置为 1×10^{-3} ,权重衰减系数为 1×10^{-4} 。学习率采用“5 个 epoch 线性 warmup + cosine annealing”策略

进行调整,batch size 设置为 16,最大训练轮数为 150,并设置 early stopping patience 为 20 以避免过拟合。训练过程启用自动混合精度训练 (Automatic mixed precision, AMP) 以提高训练效率。对于 DeepLabV3+、FPN、PSPNet、SegFormer 和 U-Net,首层输入通道数均调整为与 Sentinel-2 双时相 28 通道特征一致。

同时采用总体精度指标和边界敏感指标进行综合评价。总体精度指标包括总体精度 (OA)、交并比 (IoU) 和 F1 值;边界评价指标包括 Boundary IoU (B-IoU)、Interior IoU (I-IoU)、Edge Precision (EdgeP) 以及 B-I Gap。其中,B-IoU 用于衡量模型在田块边界区域的识别能力,I-IoU 用于衡量田块内部区域识别效果,B-I Gap 用于反映边界区域相对于田块内部区域的精度损失。

3.2 模型消融试验设置

为分析 CS-FPNet 中不同组成部分对夏玉米提取精度和边界识别能力的贡献,设置模型消融试验。消融试验按照“基础模型—逐模块叠加—完整模型”思路构建,共包含 5 组配置。A1 为仅使用 Sentinel-2 双时相输入并采用简单解码器的基础模型,用于检验简单解码结构下模型表现;A2 在 A1 基础上引入 FPN 多尺度解码器,作为仅使用 Sentinel-2 双时相特征的基线模型;A3 在 A2 基础上加入无人机电标标签,用于验证无人机电标覆盖先验的贡献;A4 在 A3 基础上进一步引入 BAGF 边界感知门控融合模块,作为本文完整模型;A5 将 A4 中显式边界门控替换为学习型 Sigmoid 门控,用于比较显式边界先验约束与数据驱动学习门控之间的差异。各消融组采用相同的数据划分、训练参数和评价指标,以保证性能差异主要来自模型结构和融合方式变化。

3.3 输入影像与输入特征消融试验设置

为验证 Sentinel-2 双时相影像及植被指数构建合理性,进一步设置输入影像与输入特征消融试验。考虑到无人机先验会对模型结果产生额外影响,为避免跨源信息干扰对 Sentinel-2 时相和输入特征贡献的判断,输入消融试验均基于 A2,即仅使用 Sentinel-2 双时相特征的基线模型进行,不引入无人机电标和边界先验。

具体而言,B1 仅使用 2025 年 7 月单时相 14 通道特征,B2 仅使用 2025 年 8 月单时相 14 通道特征,B3 使用 7 月和 8 月双时相原始波段特征,共 14 通道但不包含植被指数;A2 作为完整输入对照组,采用 7 月和 8 月双时相原始波段及植被指数共同构成的 28 通道输入。通过比较 B1、B2、B3 与 A2 结

果,可分别分析 7 月时相、8 月时相、双时相联合以及植被指数对夏玉米识别的作用,从而验证本文输入特征设计的合理性。

4 结果与分析

4.1 不同模型总体精度

不同模型在测试集上总体精度和 Trimap 分区评价结果如图 5 所示。由图 5a 可知,CS - FPNet + BAGF 在测试集上取得了最优的夏玉米提取效果,OA、IoU 和 F1 值分别达到 97.22%、95.23% 和 97.56%,均高于 DeepLabV3 +、FPN、PSPNet、SegFormer 和 U - Net 模型。相比 SegFormer 和 U - Net,本文方法 IoU 分别提高 1.78、1.30 个百分点,表明引入无人机电标签和边界先验后,模型能在现有 CNN 和 Transformer 语义分割模型基础上进一步提升夏玉米识别精度。




图 5 不同模型总体精度指标与 Trimap 分区指标
Fig. 5 Overall metrics and Trimap partition metrics among different models

从不同模型表现看,PSPNet 总体精度最低,IoU 为 79.23%,说明其空间金字塔池化结构在小地块破碎、边界复杂的农业景观中对局部细节恢复能力相对不足。DeepLabV3 + 和 FPN IoU 分别为 87.77% 和 86.34%,整体表现优于 PSPNet,但仍难

以充分刻画田块边界和混合像元区域。SegFormer IoU 达 93.45%,明显优于传统 CNN 基线,表明层次化 Transformer 结构在全局上下文建模方面具有一定优势。U - Net IoU 为 93.93%,在经典编码-解码结构中表现较好,说明细节恢复能力对农业地块提取具有重要作用。相比之下,CS - FPNet + BAGF 在双时相物候特征基础上进一步引入无人机电标签和边界约束,因而在总体分类精度上取得了更优结果。

4.2 Trimap 边界分区评价结果

Trimap 分区评价结果如图 5b 所示,不同模型在田块内部区域均具有较高识别精度,I - IoU 普遍接近 100%,说明大面积均质农田内部像元的识别难度相对较低。相比之下,不同模型在田块边界区域的差异更加明显,B - IoU 和 B - I Gap (图 6) 能更有效地区分模型在田块边界和混合像元区域的表现。本文方法 B - IoU 达到 91.18%,高于 DeepLabV3 +、FPN、PSPNet、SegFormer 和 U - Net,表明星机协同边界先验对田块边界混合像元区域具有更好的修正能力。




图 6 测试集各模型 B - I Gap
Fig. 6 B - I Gap among different models on test set

从 B - I Gap (图 6) 看,PSPNet 的边界-内部精度差最大,为 39.84%;DeepLabV3 + 和 FPN 的 B - I Gap 分别为 26.45% 和 29.32%,也存在较明显的边界精度衰减。SegFormer 和 U - Net 的 B - I Gap 分别为 11.64% 和 12.06%,较传统 CNN 模型明显降低,但仍高于本文方法。CS - FPNet + BAGF 的 B - I Gap 最低,仅为 8.66%,表明其能更有效地缩小田块内部与边界区域之间的精度差距。

值得注意的是,SegFormer 的 EdgeP 为 92.46%,与本文方法的 92.48% 接近,但 B - IoU 仍低于 CS - FPNet + BAGF。说明单一边缘点精度并不能完全代表边界区域的整体识别效果,本文方法在边界区域的整体重叠度和语义一致性方面更具优势。结合 B - IoU、EdgeP 和 B - I Gap 综合分析,CS - FPNet + BAGF 在田块边界保持和混合像元识别方面表现更优。

图 7 (图中绿色表示正确识别的夏玉米像元、红




图 7 测试集典型样区不同模型夏玉米提取结果

Fig. 7 Summer maize extraction results of different models in typical test area

色表示误检像元) 为部分模型夏玉米提取效果, 从误差来源看, 夏玉米与非夏玉米间的混分主要出现在田块边缘、果园边缘、其他夏播作物、道路两侧植被和村庄周边零散植被区域。上述地物在 7—8 月具有较高植被覆盖度或复杂空间边界, 在 Sentinel-2 10 m 像元尺度下易与夏玉米形成光谱相似或空间混合。因此, 不同模型的精度差异主要体现在边界和混合像元区域, 而非大面积均质田块内部区域。本文提出的边界约束融合方法能在一定程度上缓解此类混分问题。

4.3 模型消融试验结果

模型消融试验结果如表 5 所示。仅使用 Sentinel-2 双时相输入并采用简单解码器的 A1 已取得较好的主体区域识别能力, OA、IoU 和 F1 值分别为 96.05%、93.34% 和 96.55%, 但 B-IoU 仅为 86.78%, B-I Gap 为 13.09%, 表明简单解码结构对田块边界和局部空间结构的恢复能力仍然有限。将简单解码器替换为 FPN 后, A2 的 OA、IoU 和 F1 值分别提升至 96.80%、94.52% 和 97.19%, B-IoU 提升至 89.04%, B-I Gap 降至 10.82%, 表明多尺度特征自顶向下融合能够更好地恢复夏玉米田块结构和边界细节。

表 5 模型消融试验结果

Tab. 5 Results of model component ablation experiments

experiments							%
编号	OA	IoU	F1 值	B-IoU	I-IoU	EdgeP	B-I Gap
A1	96.05	93.34	96.55	86.78	99.86	88.61	13.09
A2	96.80	94.52	97.19	89.04	99.87	91.60	10.82
A3	97.06	94.89	97.38	89.97	99.68	94.95	9.71
A4	97.22	95.23	97.56	91.18	99.84	92.48	8.66
A5	96.81	94.54	97.19	89.87	99.73	92.22	9.86

在 A2 基础上加入 UAV 软标签后, A3 的 OA、IoU 和 F1 值分别提升至 97.06%、94.89% 和 97.38%, B-IoU 提升至 89.97%, EdgeP 明显提升至 94.95%, 表明无人机提供的子像元作物覆盖信息有助于改善 Sentinel-2 10 m 像元内部的混合现象, 尤其对边界定位具有积极作用。进一步引入 BAGF 显式边界门控后, A4 即本文完整模型的 IoU 提升至 95.23%, B-IoU 提升至 91.18%, B-I Gap 进一步缩小至 8.66%, 表明边界先验并不是简单增加额外特征, 而是能将无人机信息更有针对性地注入田块边界和混合像元区域, 从而提升边界保持能力。

需要注意的是, 与 A3 相比, A4 的 EdgeP 由

94.95%降至 92.48%，并未继续上升；但与此同时，B-IoU 继续提升，B-I Gap 继续减小。表明 BAGF 更侧重提高边界区域的整体重叠度与分类一致性，而不是单纯追求边缘位置的局部精确匹配。因此，边界性能应结合 B-IoU、EdgeP 和 B-I Gap 进行综合评价。A5 学习型门控模型的 IoU、B-IoU 和 B-I Gap 分别为 94.54%、89.87% 和 9.86%，均未达到显式边界门控模型 A4 的水平，表明在当前数据条件下，直接通过数据驱动方式学习门控权重的泛化能力有限，而基于无人机边界先验构建的显式门控更能准确约束信息注入位置。

4.4 输入影像与输入特征消融试验结果

输入影像与输入特征消融试验结果如表 6 所示。仅使用 7 月单时相特征时，B1 的 OA、IoU 和 F1 值分别为 87.63%、78.95% 和 88.24%，明显低于其他输入配置，且 B-IoU 仅为 64.07%，表明在 7 月时相下，部分夏玉米地块仍处于冠层快速形成阶段，与其他植被或背景地物之间的可分性不足，难以独立支撑稳定的夏玉米提取。相比之下，仅使用 8 月单时相特征的 B2 取得了更高精度，OA、IoU 和 F1 值分别达到 95.79%、92.92% 和 96.33%，表明 8 月冠层结构和光谱响应更稳定，是夏玉米识别的重要时相窗口。

表 6 输入影像与输入特征消融试验结果

Tab.6 Results of input image and feature ablation experiments

	%						
编号	OA	IoU	F1 值	B-IoU	I-IoU	EdgeP	B-I Gap
B1	87.63	78.95	88.24	64.07	91.18	88.39	27.10
B2	95.79	92.92	96.33	85.40	99.90	87.87	14.50
B3	96.74	94.39	97.11	89.33	99.62	93.16	10.29
A2	96.80	94.52	97.19	89.04	99.87	91.60	10.82

进一步比较 B2 和 B3 可见，在 8 月单时相基础上加入 7 月原始波段后，B3 的 OA、IoU 和 F1 值分别提升至 96.74%、94.39% 和 97.11%，B-IoU 提升至 89.33%，EdgeP 提升至 93.16%，表明 7 月信息虽难以单独完成稳定识别，但与 8 月影像共同构成的双时相变化过程，仍能为模型提供有效的光谱-物候互补信息。因此，选取 7—8 月双时相作为关键识别窗口是合理的，目的并非完整描述夏玉米全生育期，而是利用由快速生长到冠层相对稳定阶段的关键差异增强目标可分性。

将 B3 与完整输入对照组 A2 比较可见，加入植被指数后，OA、IoU 和 F1 值由 96.74%、94.39% 和 97.11% 小幅提升至 96.80%、94.52% 和 97.19%，表明植被指数在总体类别判别层面提供了轻微但稳定的增益。与此同时，B3 的 B-IoU、EdgeP 和 B-I

Gap 分别为 89.33%、93.16% 和 10.29%，略优于 A2 的 89.04%、91.60% 和 10.82%，表明植被指数并非在所有边界指标上都带来单调提升。总体而言，双时相输入是主要贡献来源，植被指数更多提供显式特征补充，而边界细节仍更依赖于双时相原始光谱变化及后续边界先验约束。

5 讨论

5.1 BAGF 模块对边界提取的作用机制

Sentinel-2 影像具有较好的区域覆盖能力和时相连续性，但空间分辨率 10 m 在小地块农田、道路-农田交界和村庄周边耕地等区域易产生混合像元，导致田块边界识别精度下降。BAGF 模块作用在于将无人机影像提供的高分辨率边界结构信息转化为卫星特征融合过程的空间门控约束，使无人机先验信息主要作用于田块边界和混合像元区域。与直接拼接或加性融合不同，BAGF 并不将无人机信息均匀施加到所有像元，而是利用 U_{bound} 提供的边界位置权重，引导模型在边界区域进行特征修正，在田块内部区域则尽量保持 Sentinel-2 双时相物候特征的主导作用。该设计能够减少无差别融合对稳定区域的干扰，同时增强边界处的空间结构表达。

消融试验结果表明，无人机软标签主要提升了模型对像元内部作物覆盖概率的表达能力，而 BAGF 进一步增强了边界区域的定向修正能力。二者作用具有互补性：前者侧重“作物覆盖信息补充”，后者侧重“边界空间位置约束”。因此，CS-FPNet 能同时利用 Sentinel-2 物候信息、无人机作物覆盖概率和边界结构先验，提高夏玉米种植区整体提取精度和田块边界保持能力。

5.2 无人机数据在星机协同中作用定位

在区域尺度农业遥感应用中，无人机影像具有厘米级空间分辨率，可清晰表达作物冠层、田埂和道路-农田交界等细节信息，但受航时、作业成本、天气和空域条件限制，难以直接承担大范围制图任务。相比之下，Sentinel-2 影像覆盖范围广、获取稳定，更适合作为区域尺度作物提取的主体数据源。

本文结果表明，无人机数据在星机协同框架中更适合作为局部高精度空间先验来源，而不是简单替代卫星影像。通过将无人机红边影像转化为 U_{soft} 和 U_{bound} ，模型能在训练阶段学习高分辨率局部结构与卫星 10 m 像元之间的对应关系，从而提升卫星模型在边界混合像元区域的识别能力。该思路为“有限无人机样本辅助大范围卫星制图”提供了一种可行实现方式。

5.3 方法局限性与未来工作

本文方法仍存在一定局限性。首先,当前研究主要针对关中平原夏玉米二分类任务开展验证,尚未扩展到多作物类别制图场景;其次,无人机影像覆盖范围有限,虽然结果表明边界先验能改善田块边界混合像元识别效果,但仍需在更多县区、更多地块类型和不同年份影像上进一步验证方法稳定性;再次,测试集仅包含 2 个独立县区,可初步评价模型的跨县区迁移能力,但尚不足以支撑全省范围内稳定泛化结论。此外,仅采用 7—8 月双时相影像虽能覆盖关中平原夏玉米较典型的关键识别窗口,但尚未完整覆盖播种、出苗和成熟等全部生育阶段。对于晚播、长势异常或田间管理差异较大的地块仍可能存在识别不足,后续将进一步引入更多时相影像构建完整多时相序列。

需要说明的是,CS - FPNet + BAGF 完整模型在进行边界精化时需无人机软标签 U_{soft} 和边界先验 U_{bound} 作为辅助输入。因此,该方法更适用于“Sentinel - 2 全域初步提取 + 无人机覆盖区域局部边界精化”的星机协同应用场景,而非完全脱离无人机数据的纯卫星推理场景。对于未被无人机影像覆盖区域,可采用 Sentinel - 2 分支或 S2 - only 模型进行区域尺度预测;对于重点区域、典型样区或边界复杂区域,可补充无人机采样并生成局部先验,用于提升边界识别精度。后续研究可进一步探索知识蒸馏、辅助监督或伪先验生成方法,使无人机信息更多地作用于训练阶段,从而降低推理阶段对无人机数据的依赖。

6 结论

(1)构建了基于星机协同与边界约束的夏玉米精准提取方法 CS - FPNet + BAGF,以 Sentinel - 2 双时相光谱-植被指数特征作为主体输入,利用无人机软标签和边界先验补充局部高分辨率空间结构信

息,实现了卫星物候特征与无人机边界先验的协同建模。试验结果表明,所提方法在夏玉米总体提取精度上优于 DeepLabV3 +、FPN、PSPNet、SegFormer 和 U - Net 等模型,能较好适应关中平原小地块、破碎化和边界复杂的农业景观。

(2)Trimap 边界分区评价结果进一步表明,模型性能差异主要集中在田块边界和混合像元区域,而田块内部区域不同模型差异较小。CS - FPNet + BAGF 能有效降低边界区域相对于田块内部区域的精度损失,表明无人机边界先验对缓解 Sentinel - 2 影像中田块边缘错分、漏分和边界外扩问题具有积极作用。与仅依赖卫星影像的 CNN 或 Transformer 模型相比,本文方法在边界区域整体重叠度和语义一致性方面表现更稳定。

(3)模型组件消融试验结果验证了 FPN 多尺度解码器、无人机软标签和 BAGF 边界感知门控融合模块的有效性。FPN 有助于增强多尺度田块结构表达;无人机软标签能够补充 10 m 像元内部的作物覆盖信息;BAGF 则进一步将无人机先验约束到边界和混合像元区域。与学习型门控相比,显式边界门控在当前有限无人机样本条件下表现更稳定,表明利用无人机边界先验直接约束信息注入位置更符合农田边界识别需求。

(4)输入影像与输入特征消融试验结果表明,7—8 月双时相 Sentinel - 2 影像能作为夏玉米种植区提取的关键识别窗口。8 月影像对冠层稳定阶段的夏玉米识别贡献较大,7 月影像虽单独识别能力有限,但与 8 月影像联合后能补充夏玉米由快速生长到冠层相对稳定阶段的光谱-物候变化信息。植被指数可在原始波段基础上提供植被覆盖、红边响应和水分状态等显式特征补充,对总体分类精度具有一定增益,但边界细节仍主要依赖双时相原始光谱变化及无人机边界先验约束。

参 考 文 献

[1] 冯权龙,牛博文,朱德海,等. 土地利用/覆被深度学习遥感分类研究综述[J]. 农业机械学报,2022,53(3):1 - 17.
Feng Quanlong, Niu Bowen, Zhu Dehai, et al. Review for deep learning in land use and land cover remote sensing classification [J]. Transactions of the Chinese Society for Agricultural Machinery,2022, 53(3):1 - 17. (in Chinese)

[2] Drusch M, Del Bello U, Carlier S, et al. Sentinel - 2: ESA's optical high-resolution mission for GMES operational services[J]. Remote Sensing of Environment, 2012, 120: 25 - 36.

[3] 陈仲新,任建强,唐华俊,等. 农业遥感研究应用进展与展望[J]. 遥感学报, 2016, 20(5): 748 - 767.
Chen Zhongxin, Ren Jianqiang, Tang Huajun, et al. Progress and perspectives on agricultural remote sensing research and applications in China[J]. Journal of Remote Sensing, 2016, 20(5): 748 - 767. (in Chinese)

[4] 史舟,梁宗正,杨媛媛,等. 农业遥感研究现状与展望[J]. 农业机械学报,2015,46(2):247 - 260.
Shi Zhou, Liang Zongzheng, Yang Yuanyuan, et al. Status and prospect of agricultural remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery,2015,46(2):247 - 260. (in Chinese)

[5] 孟凤,朱庆伟,董士伟,等. 基于多季相分形特征的 Landsat 8 OLI 影像耕地信息提取方法[J]. 农业机械学报,2024, 55(6):168 - 177.
Meng Feng, Zhu Qingwei, Dong Shiwei, et al. Cropland information extraction method of Landsat 8 OLI images based on multi-

- seasonal fractal features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(6): 168–177. (in Chinese)
- [6] 郭交, 王鹤颖, 项诗雨, 等. 基于多特征优化的 PolSAR 数据农作物精细分类方法[J]. 农业机械学报, 2024, 55(9): 275–285.
Guo Jiao, Wang Heying, Xiang Shiyu, et al. Crop classification based on PolSAR data using multiple feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 275–285. (in Chinese)
- [7] 宁纪锋, 倪静, 何义佳, 等. 基于卷积注意力的无人机多光谱遥感影像地膜农田识别[J]. 农业机械学报, 2021, 52(9): 213–220.
Ning Jifeng, Ni Jing, He Yijia, et al. Convolutional attention based plastic mulching farmland identification via UAV multispectral remote sensing image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(9): 213–220. (in Chinese)
- [8] 李林源, 黄华国, 穆西哈, 等. 低空无人机植被定量遥感: 进展、挑战与展望[J]. 遥感学报, 2025, 29(6): 2083–2113.
Li Linyuan, Huang Huaguo, Mu Xihan, et al. Low-altitude UAV quantitative remote sensing of vegetation: advances, challenges, and prospects[J]. National Remote Sensing Bulletin, 2025, 29(6): 2083–2113. (in Chinese)
- [9] 刘成良, 林洪振, 李彦明, 等. 农业装备智能控制技术研究现状与发展趋势分析[J]. 农业机械学报, 2020, 51(1): 1–18.
Liu Chengliang, Lin Hongzhen, Li Yanming, et al. Analysis on status and development trend of intelligent control technology for agricultural equipment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 1–18. (in Chinese)
- [10] 周慧, 石海滨, 张文聪, 等. 有机无机氮配施对玉米产量和硝态氮淋失的影响[J]. 农业机械学报, 2021, 52(9): 291–301, 249.
Zhou Hui, Shi Haibin, Zhang Wencong, et al. Evaluation of organic-inorganic nitrogen application on maize yield and nitrogen leaching by DNDC model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(9): 291–301, 249. (in Chinese)
- [11] Belgiu M, Csillik O. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis[J]. Remote Sensing of Environment, 2018, 204: 509–523.
- [12] Rouse J W, Haas R H, Schell J A, et al. Monitoring vegetation systems in the Great Plains with ERTS[C]//Proceedings of the Third Earth Resources Technology Satellite Symposium, 1974: 309–317.
- [13] Huete A R. A soil-adjusted vegetation index (SAVI)[J]. Remote Sensing of Environment, 1988, 25(3): 295–309.
- [14] Jiang Z, Huete A R, Didan K, et al. Development of a two-band enhanced vegetation index without a blue band[J]. Remote Sensing of Environment, 2008, 112(10): 3833–3845.
- [15] Gao B C. NDWI: a normalized difference water index for remote sensing of vegetation liquid water from space[J]. Remote Sensing of Environment, 1996, 58(3): 257–266.
- [16] 金梦婷, 徐权, 郭鹏, 等. 基于面向对象多特征学习的无人机影像农作物精细分类方法[J]. 遥感技术与应用, 2023, 38(3): 588–598.
Jin Mengting, Xu Quan, Guo Peng, et al. Crop classification from UAV images based on object-oriented multi-feature learning[J]. Remote Sensing Technology and Application, 2023, 38(3): 588–598. (in Chinese)
- [17] Zheng Z, Yuan J, Yao W, et al. Fusion of UAV-acquired visible images and multispectral data by applying machine-learning methods in crop classification[J]. Agronomy, 2024, 14(11): 2670.
- [18] Matese A, Toscano P, Di Gennaro S F, et al. Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture[J]. Remote Sensing, 2015, 7(3): 2971–2990.
- [19] 秦肖伟, 程博, 杨志平, 等. 基于时序遥感影像的西南山区地块尺度作物类型识别[J]. 地球信息科学学报, 2023, 25(3): 654–668.
Qin Xiaowei, Cheng Bo, Yang Zhiping, et al. Parcel-scale crop-type identification in a southwestern mountainous area based on time-series remote sensing images[J]. Journal of Geo-information Science, 2023, 25(3): 654–668. (in Chinese)
- [20] Rußwurm M, Körner M. Self-attention for raw optical satellite time series classification[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 169: 421–435.
- [21] Garnot V S F, Landrieu L, Giordano S, et al. Satellite image time series classification with pixel-set encoders and temporal self-attention[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 12325–12334.
- [22] Turkoglu M O, D'Aronco S, Perich G, et al. Crop mapping from image time series: deep learning with multi-scale label hierarchies[J]. Remote Sensing of Environment, 2021, 264: 112603.
- [23] Canny J. A computational approach to edge detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986, 8(6): 679–698.
- [24] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention, 2015: 234–241.
- [25] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 936–944.
- [26] Cheng B, Girshick R, Dollár P, et al. Boundary IoU: improving object-centric image segmentation evaluation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 15334–15342.
- [27] Zhao H, Shi J, Qi X, et al. Pyramid scene parsing network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 2881–2890.
- [28] Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Proceedings of the European Conference on Computer Vision, 2018: 833–851.