

基于多指数递进耦合的设施农业大棚识别方法

石宇辰 王虹扬 代莹 马瑜蔓 吴文斌 宋茜
(中国农业科学院农业资源与农业区划研究所, 北京 100081)

摘要: 准确获取农业大棚的空间分布信息对于保障粮食安全、优化设施农业布局 and 推动乡村振兴具有重要意义。为了实现大范围、自动化的大棚识别与监测,基于 Sentinel-2 影像数据,以山东省寿光市为研究区,提出了一种基于光谱-纹理特征融合的样本自动生成与筛选方法。首先,融合 APGI、RPGI、PMLI、EWI、NDVI 及缨帽变换特征,结合 Cohen's d 效应量加权阈值分割生成潜在大棚样本;进一步引入旋转不变局部二值模式(Local binary pattern, LBP)纹理特征进行筛选,获得高置信度自动样本。随后,从样本分布一致性与分类性能两方面评价其可靠性,并结合随机森林(Random forest, RF)、支持向量机(Support vector machine, SVM)和梯度提升决策树(Gradient boosting decision tree, GBDT)开展分类试验。结果表明,样本容量为 150 时自动生成样本与人工样本一致性最佳;GBDT 分类效果最优,总体精度达到 95.0%,与人工样本训练结果接近。海曙区扩展试验中,总体精度和 Kappa 系数分别达到 89.2% 和 0.83,说明该方法在复杂分散大棚场景下仍具有较好适用性。与 Global-PCG-10 对比发现,本文结果在寿光市与该数据集具有较高的空间一致性,交并比为 0.728;在海曙区复杂场景中交并比为 0.290。该方法在显著降低人工标注成本的同时仍能保持较高的分类精度,为设施农业自动化监测及样本自生成研究提供了可行路径和技术支撑。

关键词: 设施农业大棚; 识别; 样本自动生成; Sentinel-2; 机器学习

中图分类号: S127 文献标识码: A 文章编号: 1000-1298(2026)21-0280-12 **OSID:** 

Progressive Coupling of Multiple Greenhouse Indices for Greenhouse Identification in Facility Agriculture

Shi Yuchen Wang Hongyang Dai Ying Ma Yuman Wu Wenbin Song Qian
(Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences, Beijing 100081, China)

Abstract: Accurate acquisition of the spatial distribution of agricultural greenhouses is of great significance for ensuring food security, optimizing the layout of facility agriculture, and promoting rural revitalization. To achieve large-scale and automated greenhouse identification and monitoring, an automatic sample generation and screening method was proposed based on spectral-textural feature fusion using Sentinel-2 imagery, with Shouguang City, Shandong Province, as the study area. Firstly, APGI, RPGI, PMLI, EWI, NDVI, and tasseled cap transformation features were integrated, and potential greenhouse samples were generated through weighted threshold segmentation based on Cohen's d effect size. Rotation-invariant local binary pattern (LBP) texture features were then introduced for further screening to obtain high-confidence automatically generated samples. Subsequently, the reliability of the generated samples was evaluated from the perspectives of sample distribution consistency and classification performance, and classification experiments were conducted by using RF, SVM, and GBDT. The results showed that the automatically generated samples achieved the highest consistency with manually labeled samples when the sample size was 150. GBDT yielded the best classification performance, with an overall accuracy of 95.0%, which was close to that obtained by using manually labeled samples. In the extended experiment conducted in Haishu District, the overall accuracy and Kappa coefficient reached 89.2% and 0.83, respectively, indicating that the proposed method

收稿日期: 2026-04-12 修回日期: 2026-05-25
基金项目: 北京市自然科学基金项目(6242030)
作者简介: 石宇辰(2002—),男,硕士生,主要从事农业遥感研究,E-mail: 821012430312@caas.cn
通信作者: 宋茜(1985—),女,研究员,博士,主要从事耕地资源遥感研究,E-mail: songqian01@caas.cn

maintained good applicability in complex and spatially scattered greenhouse scenarios. Comparison with Global – PCG – 10 showed that the proposed results exhibited high spatial consistency with the dataset in Shouguang, with an intersection over union (IoU) of 0.728, whereas the IoU decreased to 0.290 in the more complex scenario of Haishu District. The proposed method significantly reduced the cost of manual labeling while maintaining high classification accuracy, providing a feasible pathway and technical support for automated monitoring of facility agriculture and research on self-generated samples.

Key words: facility agriculture greenhouse; identification; automatic sample generation; Sentinel – 2; machine learning

0 引言

设施农业是中国农业现代化发展的重要组成部分。2023 年中国设施农业面积已超过 500 万公顷, 占全球设施农业面积的 40% 以上, 其中大棚设施农业占比超过 70%^[1]。日光温室、塑料大棚等设施有效突破了自然条件与季节限制, 提升了农产品周年化和集约化供给能力^[2]。因此, 准确掌握农业大棚空间分布, 对优化设施农业布局、保障粮食和重要农产品稳定供给具有重要意义。

遥感影像已成为识别农业大棚空间分布及其动态变化的重要数据来源^[3]。特别是随着中高分辨率遥感影像的广泛应用与数据共享, 如高分辨率航空正射影像^[4]、吉林一号卫星遥感影像、GF-2 遥感影像、Sentinel-1/2 遥感影像和中分辨率 Landsat 影像等^[5-8], 其丰富的空间细节能够清晰呈现农业大棚结构与布局特征, 显著提升了目标识别的能力。然而, 设施农业大棚在空间分布上往往具有分布密集、棚体跨度各异等特点, 且农业大棚类型多样, 覆膜材质不同, 导致其在高分影像上的光谱特征差异明显, 同物异谱现象较为突出^[9], 给准确、自动化提取农业大棚信息带来了一定挑战。

基于遥感的农业大棚识别方法可分为基于经验指数的方法和分类器法^[10-11]。文献[12]利用冬季大棚棚顶出现冷凝水的特性, 构建增强型水体指数 (Enhanced water index, EWI) 对塑料大棚进行分类。改进塑料大棚指数^[11] (Advanced plastic greenhouse index, APGI)、塑料大棚指数^[10] (Plastic greenhouse index, PGI)、倒退式塑料大棚指数 (Retrogressive plastic greenhouse index, RPGI)、塑料薄膜覆被指数^[13] (Plastic-mulched landcover index, PMLI) 和温室检测指数^[14] (Greenhouse detection index, GDI) 等经验指数法, 充分利用大棚覆膜的高反射等光谱特征, 计算高效, 但易受裸土、建筑等相似地物干扰^[13], 且对棚膜老化、污损及复杂背景较为敏感, 容易产生漏检或误检。分类器法, 特别是主动学习、半监督学习、生成式模型和迁移学习等先进策略^[15-18], 能够自动学习目标的光谱、纹理及时序特征, 具有较大的

分类潜力^[18-19]。

近年来, 深度学习为农业大棚遥感识别提供了新的技术路径。相比经验指数阈值法和传统机器学习方法, 卷积神经网络、U-Net 等深度模型能够自动提取大棚的光谱、纹理、形状及空间上下文特征, 在高分辨率影像精细提取和复杂背景抑制方面表现出较强优势^[20]。文献[21]利用 PlanetScope、Sentinel-2 等多源遥感数据结合人工智能方法, 绘制了 2019 年全球温室种植分布图, 表明深度学习已具备支撑全球尺度温室制图的应用潜力。文献[22]进一步基于 2020 年 Sentinel-2 影像构建了 10 m 全球塑料覆盖大棚数据集 Global – PCG – 10, 并通过随机森林弱标签、APC-Net 深度学习模型和主动学习策略提升了大范围制图精度。然而, 深度学习模型的性能高度依赖训练样本的数量、质量和空间代表性, 尤其在地形复杂、大棚分散和背景地物混杂区域, 高质量样本获取与噪声样本控制仍是限制大棚遥感制图精度和跨区域推广的重要因素。

在复杂农业区或大面积应用中, 实地样本获取成本高昂^[23-25]; 而依赖目视解译、历史产品或自动生成样本等方式, 则分别面临主观性强、旧数据误差或可靠性不足的挑战^[16, 24]。因此, 充分挖掘遥感影像特征间的互补信息与深层耦合规律, 发展低依赖、高鲁棒性的样本自动生成解决方案, 是提升农业大棚遥感制图实用性的关键^[24-25]。

基于此, 本文构建多指数递进耦合的农业大棚识别方法。基于农业大棚经验指数加权合成的自适应筛选策略, 自动生成潜在大棚样本; 从组间分离度、分布拟合度、决策准确度等多个维度评价自动生成可靠性。通过对比不同光谱指数组合与权重策略分类精度, 探究多指数递进耦合方法对农业大棚识别的影响机制, 以为大尺度农业大棚快速精确识别提供理论支撑和方法参考。

1 研究区与数据来源

1.1 研究区概况

本文以山东省寿光市为主要研究区。寿光市位于山东省中北部, 地处北纬 36°41′ ~ 37°19′、东经

118°32′~119°10′,是中国典型的设施农业集中分布区。区域内农业大棚数量多、分布密集,兼有居民点、道路、果园及露天菜地等地物类型。大棚整体呈集中连片、排列较规则的空间格局,但受棚体类型、覆膜状态及局部破损等因素影响,仍存在一定识别难度。

为检验本文方法在复杂背景下的适用性,进一步选取浙江省宁波市海曙区作为扩展验证区。海曙区位于北纬 29°50′~30°00′、东经 121°30′~

121°40′,地形以丘陵、河谷和平原过渡区为主。该区大棚多呈零散、小斑块分布,并与居民点、道路及裸地等地物交错,背景异质性较强,可用于检验本文方法在复杂分散场景中的推广能力。

为保证逻辑链条清晰,本文以寿光市作为主要试验区,详细阐述自动样本生成、特征组合优选、样本容量确定及分类精度评价过程;海曙区作为扩展验证区,用于检验该方法在地形复杂、大棚分散分布条件下的适用性。图 1 为研究区地理位置图。




图 1 研究区地理位置
Fig. 1 Study area geographical location

1.2 遥感数据及预处理

本文基于 2020 年覆盖研究区的 95 景 Sentinel-2 地表反射率影像提取农业大棚空间分布。Sentinel-2A/B 重访周期为 5 d,包含 10、20、60 m 多尺度波段。本文利用 GEE 平台的 Cloud Probability 产品和 QA60 波段进行云及云阴影掩膜,并采用全年中值合成生成 10 m 影像数据集。

1.3 大棚样本及辅助数据

本文共采用样本点 300 个,其中塑料大棚样本点和其他类别样本点各 150 个,主要来源于实地采集和人工目视解译。2020 年 10 月,结合寿光市农作物物候情况开展实地采样,获取塑料大棚和其他类别样本点各 100 个;同时,结合 Sentinel-2 真彩色、假彩色影像及 Google Earth 同期历史影像,补充解译两类样本点各 50 个。随机选取总样本的 70% 作为训练样本,剩余 30% 作为验证样本。

此外,本文使用 ALOS(Advanced land observing satellite)2020 年 12.5 m DEM 数据,利用双线性插值将分辨率重采样至 10 m,用于辅助 LBP 纹理提取。

为验证结果的精度,本文引入 Global-PCG-10 数据集作对比。Global-PCG-10 是基于 2020 年 Sentinel-2 多时相影像生成的 10 m 全球塑料覆盖大棚数据集,采用 GEE 随机森林生成初始弱标签,并结合 APC-Net 深度学习模型和主动学习策略进行优化。由于该数据集与本文研究年份、主要遥感数据源和空间分辨率基本一致,因此适合用于对本文 2020 年农业大棚识别结果进行外部一致性评价。

2 技术方法

本文构建多大棚指数递进耦合的自动样本生成与识别流程。首先,基于 Sentinel-2 影像提取光谱

指数、缨帽变换分量和 LBP 纹理特征;其次,利用经验指数加权合成与多维约束筛选生成高置信度大棚样本;随后,通过样本可靠性评价、不同指数组合情

景试验及分类器对比确定最优配置;最后,在海曙区开展跨区域扩展验证,并与 Global-PCG-10 数据集进行对比分析。技术路线见图 2。




图 2 技术路线图
Fig. 2 Flowchart of proposed method

2.1 农业大棚特征提取

为充分表征农业大棚的光谱、物理属性与空间纹理特征,本文构建包含单波段、光谱指数、LBP 纹理和缨帽变换分量在内的 21 维特征集合^[26](表 1)。其中,APGI、RPGI、PMLI、EWI 和 NDVI 用于刻画棚膜反射特征、背景抑制信息及植被差异;LBP 用于描述棚体规则排列形成的局部纹理结构^[4];缨帽变换所得 Bright、Green 和 Wet 分量用于补充亮度、绿度与湿度信息^[27]。上述特征共同服务于后续自动样本筛选与分类建模。

表 1 农业大棚特征及其描述

Tab.1 Features and descriptions of agricultural greenhouses			
特征类型	特征指标	指标说明	指标数量
单波段	B^*	$B_1 \sim B_8、B_{8A}、B_9、B_{11}、B_{12}$	12
	APGI	$100B_1B_4 \frac{2B_8 - (B_4 + B_{12})}{2B_8 + B_4 + B_{12}}$	
	RPGI	$\frac{B_2}{1 - (B_2 + B_3 + B_8) / 3}$	
光谱指数	PMLI	$\frac{B_{11} - B_4}{B_{12} + B_4}$	5
	EWI	$\frac{B_3 - B_{11}}{B_3 + B_{11}} + \frac{B_3 - B_8}{B_3 + B_8} - \frac{B_8 - B_4}{B_8 + B_4}$	
	NDVI	$\frac{B_8 - B_4}{B_8 + B_4}$	
纹理	LBP	$LBP_{p,r}^i = \min(ROR(LBP_{p,r}^{ri}, i) i = 0, 1, 2, \dots, p - 1)$	1
缨帽变换	Bright、Green	$Y = Cx + b$	3
	Wet		

注:特征中 B^* 为 Sentinel-2 的光谱波段。式中 $LBP_{p,r}^i$ 为旋转不变算子, $ROR(x, i)$ 表示对 p 位二值化后的二进制右移 i 位,等价于对图像按顺时针方向旋转 i 次(p 次表示旋转一周)。Bright、Green、Wet 为缨帽变换所得亮度、绿度、湿度 3 个分量。

2.2 农业大棚经验指数加权合成的自适应筛选法

为自动生成高置信度农业大棚样本,本文构建基于大棚指数加权合成的自适应筛选方法。首先,基于 Sentinel-2 影像计算 NDVI、EWI、APGI、PMLI 和 RPGI,并按照 3 倍四分位距法剔除指数异常值。通过分析人工标注的样本分布,以各指数的第一四分位数 Q_1 和第三四分位数 Q_3 作为阈值进行二值化分割,并结合 Cohen's d 效应量的绝对值确定各指数权重,形成各像元的加权复合指标 (Composite index, CPI),从而生成具备大棚光谱特征的农业大棚潜在样本集。CPI 的计算公式为

$$CPI = \sum_{k=1}^5 w_k Binary_k$$

(1)

式中, w_k 为第 k 个指数的权重,由对应指数的 Cohen's d 效应量绝对值归一化得到; $Binary_k$ 为根据指数阈值(第一四分位数 Q_1 与第三四分位数 Q_3) 进行二值化后的结果。

在潜在样本基础上,进一步利用缨帽变换亮度、绿度和湿度分量构建物理属性约束,并结合 LBP 纹理特征剔除高反射裸地、硬化地表及纹理不规则伪目标,最终获得光谱、物理属性与纹理特征相对一致的高置信度大棚样本集。

2.3 不同光谱指数组合与权重策略的情景对比试验

为分析多指数递进耦合对自动样本生成质量和识别性能的影响,本文设置 5 类特征组合情景:情景 A 仅使用 APCI;情景 B 加入 RPGI;情景 C 进一步加入 PMLI;情景 D 继续加入 EWI;情景 E 综合使用 APCI、RPGI、PMLI、EWI 和 NDVI。

各情景均采用相同的样本生成框架。为保证可比性,固定分类器与训练参数,采用随机森林

(Random forest, RF)分类器对各情景生成样本进行验证,并以总体精度 (Overall accuracy, OA) 评价分类精度、以 Jeffries – Matusita 距离 (J – M 距离) 评价样本可分性,从而分析指数逐步引入对样本筛选与识别性能的影响。

2.4 农业大棚样本可靠性评估

为确定适宜样本容量,并评价自动生成样本与人工样本的一致性,本文采用分层随机抽样构建样本容量 n 为 100、150、200 共 3 类样本集,每种容量重复抽样 30 次,且大棚类与非大棚类保持 1:1 比例。

样本可靠性从组间分离度、分布拟合度以及决策准确度 3 方面进行评价。具体采用 PERMANOVA R^2 、马氏距离、J – M 距离、能量距离和 JS 距离表征自动样本与人工样本在多维特征空间中的差异,并以 OA 反映样本在分类任务中的应用效果。

2.5 分类方法与精度评价

为比较不同分类器对自动生成样本的适应性,本文选取支持向量机 (Support vector machine, SVM)、RF 和梯度提升决策树 (Gradient boosting decision tree, GBDT) 开展分类试验。SVM 采用 RBF 核函数,惩罚系数 N 设为 1.0; RF 的决策树数量 $ntree$ 设为 150,节点分裂特征数 $mtry$ 设为总特征数平方根;GBDT 的基学习器数量、学习率和最大深度分别设为 100、0.1 和 3。

分类精度采用混淆矩阵评价,并选取总体精度 (OA)、Kappa 系数、生产者精度 (PA) 和用户精度 (UA) 作为评价指标。

2.6 跨区域扩展验证试验

为检验方法在复杂背景下的适用性,本文选取浙江省宁波市海曙区开展跨区域扩展验证。与寿光市相比,海曙区大棚分布更零散、地物背景更复杂,可用于检验方法在分散型设施农业场景中的推广能力。

扩展试验采用“寿光市确定最优配置,海曙区独立应用验证”的设计。基于寿光市试验结果,海曙区保持五指数协同约束、样本容量 $n = 150$ 和 GBDT 分类器不变,开展自动样本生成与分类,并基于独立参考样本评价其识别精度和适用性。

2.7 与现有产品精度对比

为评价本文识别结果的外部一致性,引入 Global – PCG – 10 进行对比分析。首先,将 Global – PCG – 10 裁剪至寿光市和海曙区范围,并统一投影、空间分辨率和像元网格,计算两类结果的大棚面积、面积差异率和交并比 (IoU);其次,基于独立参考样本构建混淆矩阵,对比 OA、Kappa 系数、PA 和 UA 等精度指标。

Global – PCG – 10 主要用于外部一致性评价,并

不作为绝对真值;对于结果差异较明显的区域,进一步结合高分辨率历史影像进行局部判读。

3 结果与分析

3.1 不同农业大棚指数组合生成样本效果评估

图 3 显示了不同农业大棚光谱指数特征贡献度差异,为基于效应量绝对值进行加权融合提供量化依据。APGI 与 RPGI 表现出最为显著的正向区分能力,其 Cohen’s d 分别高达 4.52 和 4.13,表明这两项指数能够精准捕捉大棚的高反射光谱特性,在加权体系中占据主导地位。PMLI 与 EWI 呈现出显著的负效应量 (分别为 -3.89 和 -3.71),表明大棚在这些特征空间中的响应值显著低于背景地物。尽管方向相反,但其较高的绝对值意味着两者具备极强的背景抑制能力,对于剔除由高反射地物引起的伪目标具有关键作用。相比之下,NDVI 的效应量为 3.68,虽然在 5 种指数中权重相对较低,但仍保持了良好的类别分离度。因此,基于效应量绝对值的加权策略整合了正向特征的识别优势与负向特征的噪声抑制优势,为自动样本生成提供了稳健的特征基础。




图 3 所选指数对样本筛选的效应量

Fig. 3 Selected index's effect size on sample screening

图 4、5 展示了随着大棚光谱指数的逐步引入,逐步纯化了自生成样本池,有力提升了农业大棚识别能力。从仅使用 APGI 的情景 A 至融合 APGI、RPGI、PMLI、EWI 与 NDVI 共 5 个指数的情景 E,OA 由 85.4% 提升至 95.0%,自生成农业大棚样本与其他地物间的 J – M 距离由 1.35 提高到 1.91,样本纯度逐步提升。由此可见,使用 5 种大棚专用指数,可在特征空间中构建更稳定的目标簇结构,从而实现与其他地物类型的可靠区分。情景 A 中,候选样本主要源于大棚覆膜材料及棚内背景形成的高反射光谱响应,在 10 m 空间分辨率下供提取候选像元为 4 012 032 个。然而,部分裸地、硬化地表等高反射地物与农业大棚混淆,影响了类间分离度与分类精度。情景 B 中,特征集合融合了绝对反射水平与相

对反射差异,增强了大棚覆膜特征,潜在样本降至 449 862 个,88.79% 的伪目标被剔除。情景 C、D、E 在“亮度/反射差异”之外,强化了材质结构、水分背景与植被活性等多维约束,促使样本向高置信核心持续收敛。情景 C 筛选候选样本像元 64 067 个,占场景 B 的 14.24%。情景 D 加入 EWI 后进一步缩减至 17 863 个,占情景 C 的 27.88%。情景 E 的样本规模收敛至 1 082 个,占情景 D 的 6.06%。




图 4 不同特征组合情景下农业大棚潜在样本空间分布对比

Fig. 4 Spatial distribution of potential greenhouse samples under different feature combination scenarios




图 5 特征递进引入对模型精度与样本可分性的影响

Fig. 5 Impact of stepwise feature introduction on model accuracy and sample separability

3.2 自动生成样本可靠性评估

图 6 对比了自动生成样本 (Auto-generated samples, AS) 与实地样本 (Reference samples, RS) 在 5 种大棚光谱指数上的特征分布差异。总体上, AS 与 RS 在各指数上的分布中心与四分位区间高度一致,表明自动生成样本不仅能复现实测样本的中心趋势,也能较好保持类内变异幅度。在表征覆膜材料高反射特性的 APGI 与 RPGI 上,两组样本均呈高值集中且分位结构接近:APGI 中位数分别为 0.55 (AS) 与 0.53 (RS),RPGI 中位数分别为 0.185 (AS) 与 0.175 (RS),差异幅度均不超过 0.02,说明自动样本对棚膜强反射谱型的刻画与实测样本一致。用于增强大棚与亮裸地、硬化地表及湿润背景等混淆地物区分能力的 PMLI 与 EWI 同样表现为分

布高度重叠:PMLI 中位数为 0.21 (AS) 与 0.22 (RS),EWI 中位数为 0.79 (AS) 与 0.80 (RS),差异幅度均为 0.01,表明自动筛选与提纯过程有效抑制了典型伪目标混入,使背景抑制类指数的统计结构与实测样本保持一致。表征植被覆盖活性的 NDVI 中位数分别为 0.32 (AS) 与 0.31 (RS),差异为 0.01,说明自动生成样本未引入由棚内作物长势差异导致的系统性偏移。综上,5 种指数在“高反射表征-背景抑制-植被环境约束”3 个维度上均呈现出 AS 与 RS 的高度同源分布特征,验证了基于指数加权与多维约束的自动样本生成方法能够稳定复现农业大棚的典型光谱响应并控制样本变异。




图 6 自动生成样本与实测样本特征分布对比

Fig. 6 Comparison of feature distributions between automatically generated samples and reference samples

为全面验证本文提出的农业大棚经验指数加权合成的自适应筛选法对自动生成样本 (AS) 的可靠性,选用 PERMANOVA R^2 、马氏距离、J-M 距离、能量距离和 JS 距离等指标进行综合对比,结果见图 7。不同样本容量下的距离指标整体处于较低水平,表明 AS 能够较好复现 RS 的典型光谱响应结构。具体而言,当样本量偏小 ($n = 100$) 时,受地表异质性影响,样本对局部场景或少量异常像元覆盖不足,导致 PERMANOVA R^2 、能量距离、JS 距离等一致性指标出现波动。当样本量增大到 200 时,样本覆盖范围扩大虽提升了代表性,同时也增加了纳入边缘像元与混合像元的不确定性,致使分布形态与可分性产生轻微扰动,马氏距离相应增至 0.40。相比之下,样本容量为 150 时表现出最优的一致性:PERMANOVA R^2 为 0.10,表明 AS 与 RS 来源差异对特征变异的解释度较弱;J-M 距离达到最小值 0.30,说明该容量下两类样本在特征空间中分布重

叠度最高、谱型匹配最佳;马氏距离维持在 0.30 的较低水平;能量距离与 JS 距离整体较小,分别为 0.11 和 0.09,表明 AS 不仅在中心趋势上与 RS 接近,也能较好保持类内变异形态。综上,样本容量为 150 可在覆盖大棚光谱差异与控制复杂背景混淆之间取得最佳平衡。




图7 综合评价指标

Fig. 7 Comprehensive evaluation indicators

3.3 基于自动生成样本的大棚识别精度分析

图 8 展示了基于 150 个自动生成样本分别驱动随机森林 (RF)、支持向量机 (SVM) 与梯度提升决策树 (GBDT) 得到的农业大棚空间分布结果。图中 a、b、c 分别表示 3 个典型区域;a1、b1、c1 为 SVM 分类结果,a2、b2、c2 为 RF 分类结果,a3、b3、c3 为 GBDT 分类结果。总体上,3 种分类器提取的大棚空间格局具有较高一致性,均呈现明显的集聚分布特征,表现为研究区南部-东南部密集、北部-东北部稀疏的梯度格局:南部至东南部形成连片或半连片的高密度斑块带,并在中南部及东南部出现多个集聚核心区;北部及东北部大棚数量显著减少,以零散点状或小斑块为主,连片分布特征不显著。不同分类器在图斑形态与边界完整性方面存在差异:SVM 结果更易出现零散斑点与边界破碎现象;RF 能够较好保持连片区的整体性,但斑块边缘仍可能存在少量噪声;GBDT 提取的斑块连贯性更强、边界更清晰,对非目

标地物的误判抑制效果更佳。




图8 150 样本容量下不同分类器分类结果

Fig. 8 Classification results of different classifiers under 150 sample size

图 9 为基于不同容量的自动生成样本与实地样本,分别驱动 SVM、RF、GBDT 共 3 种分类器下农业大棚识别的总体精度、Kappa 系数、生产者精度和用户精度。总体来看,当自动生成样本容量为 150 或 200 时,3 种分类器总体精度均超过 85.0%,Kappa 系数达 0.80,整体表现接近人工标注样本训练结果。其中,GBDT 分类性能最优:在 150 个自动样本条件下,总体精度为 95.0%,Kappa 系数为 0.90,生产者精度为 90.0%,仅略低于人工样本训练所得的 96.0%与 0.92,表明自动样本能够有效替代人工样本完成高精度模型训练。RF 表现居中,150 个样本时总体精度为 93.0%。SVM 在三者中精度相对较低,但其性能随样本量增加而明显改善,当样本容量由 100 增至 200 时,总体精度由 89.0% 提升至 91.0%,与 RF 的差距缩小。从生产者精度看,当样本容量为 150~200 时,各分类器对大棚类别的生产者精度均在 85.0% 以上,证明基于自动样本训练的模型能够较稳定覆盖真实大棚区域;用户精度在各容量与分类器下亦保持稳定水平,整体与人工样本结果相当。

3.4 扩展研究区应用验证

为检验本文方法在复杂地形与分散大棚分布条件下的适用性,基于寿光市试验确定的最优配置,在




图9 不同分类器不同样本容量下的分类结果精度评价

Fig. 9 Evaluation of classification accuracy under different classifiers and sample sizes

浙江省宁波市海曙区开展跨区域扩展验证试验。海曙区试验采用与寿光市一致的特征构建与样本筛选流程,以 APGI、RPGI、PMLI、EWI、NDVI 共 5 类光谱指数为核心特征,结合缨帽变换分量和 LBP 纹理约束生成高置信度自动样本,并选取样本容量 $n = 150$ 训练 GBDT 分类器。

图 10 为海曙区自动生成样本与参考样本的综合评价结果。PERMANOVA R^2 、能量距离和 JS 距离均处于较低水平,表明自动生成样本与参考样本之间的整体分布差异较小;马氏距离保持在较低区间,说明两类样本的分布中心偏移有限。与寿光市结果相比,海曙区自生成样本综合指标整体差异不大,但 J-M 距离略高,反映出自动生成样本与参考样本在局部特征空间中的重叠程度有所降低。该现象可能与海曙区居民点、道路、亮裸地、硬化地表和稀疏植被等高亮背景混杂分布有关,这些地物与棚膜在部分波段上具有相似反射特征,增加了自动样本筛选的不确定性。




图 10 海曙区自生成样本综合评价指标
Fig. 10 Comprehensive evaluation indicators of auto-generated samples in Haishu

基于 $n = 150$ 自动生成样本训练的 GBDT 分类器在海曙区的分类结果如图 11 所示,本文所用方法在海曙区大棚识别中取得了 89.2% 的总体精度和

0.83 的 Kappa 系数。相较寿光市集中连片大棚区,海曙区分类精度有所下降,但在地形复杂、地块破碎和大棚分布分散的条件下仍保持较高识别水平。精度下降主要受小型棚体混合像元、复杂背景高亮地物干扰以及大棚斑块空间连续性弱等因素影响。试验结果表明,本文方法在复杂分散区域仍具有一定跨区域适用性,但对高亮地物和小型棚体的区分能力仍有进一步提升空间。




图 11 海曙区大棚分布图
Fig. 11 Distribution map of agricultural greenhouses in Haishu

3.5 与 Global - PCG - 10 数据集的对比分析

为进一步评价本文方法在 2020 年农业大棚识别中的可靠性,将本文分类结果与 Global - PCG - 10 开源全球大棚数据集进行对比分析。Global - PCG - 10 是基于 2020 年 Sentinel - 2 影像构建的 10 m 全球塑料覆盖大棚产品,具有与本文数据源、年份和空间分辨率相近的可比性。表 2 给出了寿光市和海曙区两类结果的面积及空间一致性指标。两区对比表明,本文结果与 Global - PCG - 10 在集中连片大棚区具有较高一致性,而在复杂分散大棚区差异明显增大。

表 2 本文方法与 Global - PCG - 10 的分类结果对比

区域	本文方法($n = 150$)			Global - PCG - 10			面积差异/ %	交并比
	总体精度/%	Kappa 系数	面积/ km^2	总体精度/%	Kappa 系数	面积/ km^2		
寿光市	95.0	0.90	303.014	92.2	0.84	416.266	-27.21	0.728
海曙区	89.2	0.83	3.029	81.7	0.69	10.443	-71.00	0.290

图 12 展示了寿光市典型区域中本文方法与 Global - PCG - 10 的局部对比结果。对于集中连片、棚体排列规则的大棚区,两类结果均能识别主要大棚分布范围,空间格局基本一致。差异主要体现在棚体内部细节和边界表达上。本文方法在多指数约束和 LBP 纹理筛选作用下,能够较好剥离棚间道路、棚间空隙等非大棚像元,使识别结果更接近实际

棚体覆盖范围;Global - PCG - 10 在部分区域表现为斑块连续性更强,可能将棚间道路或相邻高亮背景纳入大棚范围,导致面积估计偏大。局部放大结果显示,本文方法对稀疏植被和非棚体高亮地物的误分相对较少,但在部分边缘区域存在少量破碎斑块。

图 13 为海曙区典型区域的对比结果。海曙区大棚多呈小斑块、零散化分布,且与道路、居民点、裸




图 12 寿光市大棚识别结果与 Global-PCG-10 局部对比

Fig. 12 Local comparison of greenhouse identification results with Global-PCG-10 in Shouguang

地和稀疏植被交错分布,地物背景异质性显著高于寿光市。该条件下,两类产品的差异主要表现为 Global-PCG-10 对部分高亮地物和稀疏植被区域的包含范围较大,本文方法则通过区域自适应样本筛选和纹理约束抑制了部分伪目标,从而得到较小的识别面积。海曙区交并比(IoU)显著低于寿光市,说明在棚体尺度较小、边界不规则和背景复杂的区域,全球尺度产品与区域自适应方法之间的空间一致性会明显降低。该结果表明,Global-PCG-10 适用于大范围大棚空间格局表达,本文方法在局地精细识别中能够对棚间道路剥离和稀疏植被误分控制提供补充。




图 13 海曙区大棚识别结果与 Global-PCG-10 局部对比

Fig. 13 Local comparison of greenhouse identification results with Global-PCG-10 in Haishu

4 讨论

本文面向大范围设施农业制图中训练样本获取成本高、噪声样本难控制的核心瓶颈^[28],构建了农业大棚经验指数加权合成的自适应样本生成框架,并从样本可分性、分布一致性和分类决策性能 3 个

层面验证了其有效性。结果表明,多指数递进耦合能够推动候选样本由宽松筛选逐步向高置信核心收敛,显著提升样本纯度和类别可分性;样本规模存在适宜区间,其中 $n = 150$ 时自动样本与参考样本一致性较好,基于该样本训练的 GBDT 分类结果已接近人工样本训练水平,说明自动生成样本具备支撑高精度大棚制图的潜力。

4.1 特征重要性与信息贡献机制分析

在最佳样本容量与分类器的基础上,基于平均不纯度减少(Mean decrease in impurity, MDI)准则,量化多维特征空间中各变量对大棚识别模型的相对贡献度(图 14)。特征重要性分析表明,塑料大棚识别的有效信息主要来自两类互补维度:一是棚膜材料形成的光谱响应差异,二是棚体规则排列所呈现的空间纹理结构。前者以 APCI 等专用指数为代表,是区分大棚与一般农田背景的核心信息来源;后者以 LBP 纹理特征为代表,可在 10 m 分辨率条件下补充棚体规则性与局部空间一致性信息,降低亮裸地、硬化地表等高反射背景造成的误判。




图 14 基于 MDI 的分类特征重要性评价结果

Fig. 14 Feature importance ranking based on mean decrease in impurity (MDI)

结合指数递进情景试验结果(图 5)可进一步解释这种“光谱-结构互补”的来源机制:专用指数的递进引入实质上是在逐步补全识别所需的 3 类判别约束^[9],即反射强度(APGI/RPGL)-背景抑制(PMLI/EWI)-植被环境约束(NDVI)。随着约束维度增加,候选像元持续向高置信核心收敛(4 012 032 收敛至 1 082),类间分离度(J-M 距离)与分类精度(OA)同步提升,表明“物理可解释特征→统计可分性提升→决策性能增益”形成一致闭环。因而,在 10 m 分辨率与全年合成的条件下,本文仍能获得较高识别精度,原因在于目标类别的稳定判别信息更多来自棚膜材质与空间结构,而非完全依赖时序物候曲线。这一点与以“时间合成窗口-物候信息完整性-识别精度权衡”为主线的时序识别研究形成

互补^[29]：当目标类别的判别信息主要由材质与结构决定时,单时相或弱时序方案也能取得可用精度;而当识别强依赖物候相位时,窗口设置与时序完整性将成为主导因素。

4.2 样本规模效应与可靠性权衡机制

可靠性评估表明,自动样本规模并非越大越好,而呈现“覆盖不足-最优区间-边缘混入”的权衡关系^[30]。样本量偏小($n = 100$)时,AS 对棚体内部异质性与复杂背景组合的覆盖有限,更易对局部场景产生偏倚;样本量偏大($n = 200$)时,覆盖范围扩大虽然提高了代表性,但也更可能纳入棚体边缘像元、混合像元或非典型高反射伪目标,导致样本在联合特征空间出现漂移,从而削弱与 RS 的匹配程度。从更一般的制图经验看,文献[31]在作物制图中指出物候信息组织与训练样本稳定性会共同影响分类表现;在自动样本生成情景中,样本从“核心高置信”扩展到“覆盖更广的边缘状态”时,若缺少足够约束机制,噪声样本更容易进入训练集并放大分布偏移风险。

这种权衡可由“单变量分布一致性(图 6)-多维分布一致性(图 7)-分类决策性能(图 9)”3 层证据共同支撑:图 6 显示 5 类指数上 AS 与 RS 的分位结构整体接近,说明自动样本在关键判别维度上能够复现实测分布;但只有在 $n = 150$ 时,多维一致性达到最优——PERMANOVA R^2 为 0.10,马氏距离为 0.30,能量距离与 JS 距离为 0.09~0.11,同时 J-M 距离达到最小值 0.30,表明该规模下 AS 与 RS 的分布重叠度最高、形态最一致。进一步在分类实验中,这种“一致性最优区间”能够有效转化为更稳定的制图性能:自动样本容量达到 150 或 200 时,3 类分类器总体精度均在 85.0% 以上、Kappa 系数在 0.80 以上,其中 GBDT 在 150 个自动样本条件下总体精度为 95.0%、Kappa 系数为 0.90,接近人工样本训练结果(96.0%、0.92)。

从方法体系角度看,自动样本构建是弱监督制图的一类重要路径^[32]。文献[33]提出通过融合物候域光学-SAR 特征实现自动样本生成,强调在缺少充分真值条件下可通过多源互补与特征域约束提高样本可信度。与之相比,本文在光学指数与纹理约束基础上增加了“分布一致性-决策性能”的双重检验链条,并识别出明确的最优样本规模区间($n = 150$),为后续跨区推广提供了更可操作的配置建议。因此,建议将 $n = 150$ 作为默认样本规模配置,并优先通过“约束增强”(背景抑制、纹理补偿、多源互证)而非“无上限增样”来提升稳健性。

4.3 方法适用性与局限性分析

海曙区扩展试验表明,本文方法在复杂地形和分散大棚场景下仍具有一定适用性。与寿光市大棚集中连片、排列规则、候选样本丰富的空间格局不同,海曙区大棚多呈零散小斑块分布,并与居民点、道路、裸地、硬化地表和稀疏植被等地物交错,背景异质性和混合像元影响更强。在该条件下,基于 $n = 150$ 自动生成样本训练的 GBDT 模型仍取得 89.2% 的总体精度和 0.83 的 Kappa 系数,说明多指数递进耦合与纹理约束能够在一定程度上缓解区域背景差异对样本筛选和分类识别的影响。海曙区自生成样本综合指标较寿光市略差,尤其 J-M 距离略高,表明复杂背景下自动样本与参考样本在局部特征空间中的重叠程度有所降低。这可能与高亮建筑物、亮裸地、硬化地表等地物与棚膜存在相似光谱响应有关,导致自动样本筛选的不确定性增加。

与 Global-PCG-10 的对比进一步说明,全球尺度产品与区域自适应方法在应用定位上存在差异。寿光市中,本文结果与 Global-PCG-10 的 IoU 为 0.728,说明两者在集中连片大棚区具有较高空间一致性;海曙区中 IoU 降至 0.290,表明复杂分散区域会显著放大不同方法之间的差异。结合局部对比结果可知,本文方法能够较好剥离大棚间道路和棚间空隙,并减少稀疏植被误分,使识别结果更接近棚体实际覆盖范围;Global-PCG-10 作为全球尺度产品,在局部区域可能保留更完整的大棚聚集斑块,因而将部分棚间道路或复杂背景纳入大棚范围。这说明 Global-PCG-10 适用于大范围大棚空间格局表达,而本文方法在局地精细制图中具有补充价值。

从方法发展角度看,本文自动样本生成框架也可为弱监督和深度学习模型提供高质量初始样本。已有研究表明,深度学习在大棚遥感制图中具有较强的空间上下文表达能力^[20-22],但其性能高度依赖训练样本的数量、质量和代表性^[34]。本文通过多指数约束、缨帽变换和 LBP 纹理筛选,将潜在样本逐步收敛至高置信度样本,可降低人工标注成本并抑制噪声样本进入训练集。目前本文结果仍以 10 m Sentinel-2 像元级识别为主,在小型棚体、棚体边缘和复杂高亮背景区域仍存在一定不确定性。后续可结合 Sentinel-1 SAR 数据、高分辨率影像和对象级形状约束,进一步提升复杂分散区域中小型大棚的识别稳定性。

5 结论

(1)构建了高置信度的样本自动生成与筛选机制。提出了基于 Cohen's d 效应量权重的自适应阈

值分割策略,整合了 APGI、RPGI 等正向特征的识别优势与 PMLI、EWI 等负向特征的背景抑制能力。通过引入缨帽变换物理属性与 LBP 纹理一致性约束,构建了自动提纯机制,剔除了初步样本中的“同谱异物”噪声。多维统计检验(PERMANOVA R^2 、J-M 距离等)表明,自动生成样本与人工标注真值在特征空间分布上高度同源,验证了该方法在少人工干预下生成高质量训练数据的可靠性。

(2)揭示了样本容量与分类器性能的响应规律。对比分析了 RF、SVM 及 GBDT 共 3 种模型在不同样本容量下的表现,发现分类精度并非随样本量增加呈线性增长,而是存在边际效应。试验结果表明,当样本容量为 150 时,模型性能达到最优平衡点,既保证了特征多样性又有效控制了冗余噪声。其中,GBDT 模型凭借其对非线性特征的强大挖掘能力,在最优样本量下实现了 95.0% 的总体精度,表现出优于 RF 和 SVM 的鲁棒性与泛化能力。

(3)验证了自动化制图策略的有效性与推广潜力。本文在寿光市集中连片大棚区实现了 95.0%

的总体精度和 0.90 的 Kappa 系数;在宁波市海曙区复杂分散大棚场景中,总体精度和 Kappa 系数分别达到 89.2% 和 0.83。结果表明,本文方法不仅适用于大棚集中连片、候选样本丰富的典型设施农业区,也可推广至地形复杂、地块破碎和大棚分散分布的区域。海曙区精度略低于寿光市,主要与大棚尺度较小、背景地物复杂、高亮地物干扰和混合像元影响有关。

(4)与 Global-PCG-10 开源全球大棚数据集的对比表明,本文方法在寿光市集中连片大棚区与全球产品具有较高空间一致性, IoU 为 0.728;在海曙区复杂分散场景下,两类结果差异增大, IoU 为 0.290。差异主要来源于两类产品在局地边界表达和背景抑制能力上的不同:本文方法能够剥离大棚间道路并减少稀疏植被误分,因此面积估计较 Global-PCG-10 更小。该结果说明,全球尺度产品可为大棚宏观分布提供重要参考,而本文区域自适应样本生成方法可在局地精细制图中形成有效补充,并为弱监督或深度学习模型提供高质量初始样本支撑。

参 考 文 献

[1] 孙燕,袁一心,骆占斌,等. 中国农业温室大棚时空格局演变及影响因素[J]. 中国土地科学, 2025, 39(7): 124-136. Sun Yan, Yuan Yixin, Luo Zhanbin, et al. Spatiotemporal evolution and influencing factors of agricultural greenhouses in China [J]. China Land Science, 2025, 39(7): 124-136. (in Chinese)

[2] 肖扬,唱隽逸,杨倩,等. 覆膜农田遥感分类研究进展和展望[J]. 遥感学报, 2025, 29(12): 3435-3447. Xiao Yang, Chang Junyi, Yang Qian, et al. Remote sensing identification and classification research on plastic film-covered farmland: progress and prospects[J]. National Remote Sensing Bulletin, 2025, 29(12): 3435-3447. (in Chinese)

[3] Jimenez-Lao R, Aguilar F J, Nemmaoui A, et al. Remote sensing of agricultural greenhouses and plastic-mulched farmland: an analysis of worldwide research[J]. Remote Sensing, 2020, 12(16): 3320.

[4] 窦雅娟. 基于国产卫星数据的京津冀地区农业大棚遥感监测[J]. 智慧农业导刊, 2023, 3(13): 1-4. Dou Yajuan. Remote sensing monitoring of agricultural greenhouses in the Beijing-Tianjin-Hebei region based on domestic satellite data[J]. Journal of Smart Agriculture, 2023, 3(13): 1-4. (in Chinese)

[5] 吴锦玉,刘晓龙,柏延臣,等. 基于 GF-2 数据结合多纹理特征的塑料大棚识别[J]. 农业工程学报, 2019, 35(12): 173-183. Wu Jinyu, Liu Xiaolong, Bai Yanchen, et al. Identification of plastic greenhouses based on GF-2 data combined with multi-texture features[J]. Transactions of the CSAE, 2019, 35(12): 173-183. (in Chinese)

[6] 陆笑舒,林芬芳,缪钱龙,等. 基于 GEE 云平台和 Landsat 影像的天山北坡经济带 2000—2020 年农业大棚时空动态变化研究[J]. 地理科学, 2025, 45(7): 1590-1600. Lu Xiaoshu, Lin Fenfang, Miao Qianlong, et al. Spatiotemporal dynamics of agricultural greenhouses in the economic belt on the northern slope of the Tianshan Mountains from 2000 to 2020 based on the GEE cloud platform and Landsat imagery[J]. Scientia Geographica Sinica, 2025, 45(7): 1590-1600. (in Chinese)

[7] 解毅,王佳楠,刘钰. 基于 Sentinel-1/2 数据特征优选的冬小麦种植区识别方法研究[J]. 农业机械学报, 2024, 55(2): 231-241. Xie Yi, Wang Jia'nian, Liu Yu. Research on winter wheat planting area identification method based on Sentinel-1/2 data feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 231-241. (in Chinese)

[8] Acharki S, Veetil B K. Mapping plastic-covered greenhouse farming areas using high-resolution PlanetScope and RapidEye imagery: studies from Loukkos perimeter (Morocco) and Dalat City (Vietnam) [J]. Environmental Science and Pollution Research, 2023, 30(9): 23012-23022.

[9] Liu L, Xiao X, Qin Y, et al. Mapping cropping intensity in China using time series Landsat and Sentinel-2 images and Google Earth Engine[J]. Remote Sensing of Environment, 2020, 239: 111624.

[10] Yang D, Chen J, Zhou Y, et al. Mapping plastic greenhouse with medium spatial resolution satellite data: development of a new spectral index[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 128: 47-60.

[11] Zhang P, Du P, Guo S, et al. A novel index for robust and large-scale mapping of plastic greenhouse from Sentinel-2 images [J]. Remote Sensing of Environment, 2022, 276: 113042.

[12] 王志盼,张清凌,钱静,等. 基于增强型水体指数的大棚遥感检测研究:以广东江门地区为例[J]. 集成技术, 2017,

- 6(2): 11–21.
- Wang Zhipan, Zhang Qingling, Qian Jing, et al. Remote sensing detection of greenhouses based on enhanced water index: a case study of Jiangmen, Guangdong Province[J]. *Journal of Integrated Technology*, 2017, 6(2): 11–21. (in Chinese)
- [13] Lu L, Di L, Ye Y. A decision-tree classifier for extracting transparent plastic-mulched landcover from Landsat-5 TM images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(11): 4548–4558.
- [14] Gonzalez-Yebra O, Aguilar M A, Nemmaoui A, et al. Methodological proposal to assess plastic greenhouses land cover change from the combination of archival aerial orthoimages and Landsat data[J]. *Biosystems Engineering*, 2018, 175: 36–51.
- [15] 翟雪东, 韩文霆, 马伟童, 等. 基于改进 AdvSemiSeg 的半监督遥感影像作物制图方法[J]. *农业机械学报*, 2024, 55(8): 196–204.
- Zhai Xuedong, Han Wenting, Ma Weitong, et al. Semi-supervised network for remote sensing crop mapping based on improved AdvSemiSeg[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(8): 196–204. (in Chinese)
- [16] 杜培军, 张鹏, 郭山川, 等. 融合光谱指数与高分影像的塑料大棚语义分割模型[J]. *武汉大学学报(信息科学版)*, 2023, 48(10): 1670–1683.
- Du Peijun, Zhang Peng, Guo Shanchuan, et al. Semantic segmentation model for mapping plastic greenhouse by integrating spectral index and high-resolution imagery[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(10): 1670–1683. (in Chinese)
- [17] Sun H, Wang L, Lin R, et al. Mapping plastic greenhouses with two-temporal Sentinel-2 images and 1D-CNN deep learning[J]. *Remote Sensing*, 2021, 13(14): 2775.
- [18] 冯权泷, 牛博文, 朱德海, 等. 基于多核主动学习和多源数据融合的农田塑料覆被分类[J]. *农业机械学报*, 2022, 53(2): 177–185.
- Feng Quanlong, Niu Bowen, Zhu Dehai, et al. Classification of agricultural plastic cover based on multi-kernel active learning and multi-source data fusion[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(2): 177–185. (in Chinese)
- [19] Ye Y, Wang M, Zhou L, et al. Adjacent-level feature cross-fusion with 3-D CNN for remote sensing image change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 1–14.
- [20] Zhang M, Dong J, Ge Q, et al. A review of agricultural film mapping: current status, challenges, and future directions[J]. *Journal of Remote Sensing*, 2025, 5: 0395.
- [21] Tong X, Zhang X, Fensholt R, et al. Global area boom for greenhouse cultivation revealed by satellite mapping[J]. *Nature Food*, 2024, 5(6): 513–523.
- [22] Niu B, Feng Q, Qiu B, et al. Global-PCG-10: a 10 m global map of plastic-covered greenhouses derived from Sentinel-2 in 2020[J]. *Earth System Science Data*, 2025, 17: 5065–5088.
- [23] Hao P, Di L, Zhang C, et al. Transfer learning for crop classification with Cropland Data Layer data as training samples[J]. *Science of the Total Environment*, 2020, 733: 138869.
- [24] Cai Z W, Xu B D, Yu Q Y, et al. A cost-effective and robust mapping method for diverse crop types using weakly supervised semantic segmentation with sparse point samples[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2024, 218: 260–276.
- [25] Ma D, Tang P, Zhao L. SiftingGAN: generating and sifting labeled samples to improve the remote sensing image scene classification baseline[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(7): 1046–1050.
- [26] Gao M, Jiang Q, Zhao Y, et al. Comparison of plastic greenhouse extraction method based on GF-2 remote-sensing imagery[J]. *Journal of China Agricultural University*, 2018, 23(8): 125–134.
- [27] 朱德海, 刘逸铭, 冯权泷, 等. 基于 GEE 的山东省近 30 年农业大棚时空动态变化研究[J]. *农业机械学报*, 2020, 51(1): 168–175.
- Zhu Dehai, Liu Yiming, Feng Quanlong, et al. Spatial-temporal dynamic changes of agricultural greenhouses in Shandong province in recent 30 years based on Google Earth Engine[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(1): 168–175. (in Chinese)
- [28] Wei P, Huang R, Lin T, et al. Rice mapping in training sample shortage regions using a deep semantic segmentation model trained on pseudo-labels[J]. *Remote Sensing*, 2022, 14(2): 371.
- [29] Wen Y A, Li X C, Mu H W, et al. Mapping corn dynamics using limited but representative samples with adaptive strategies[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 190: 252–266.
- [30] Xu Y J, Ebrahimi H, Zhang Z. Bayesian joint adaptation network for crop mapping in the absence of mapping year ground-truth samples[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 1–14.
- [31] Zang Y Z, Zhou J X, Chen X H, et al. Integrating classifier transfer and sample transfer strategies for in-season crop mapping based on sample weighting technique[J]. *Remote Sensing of Environment*, 2026, 334: 115208.
- [32] Mohammadi S, Belgiu M, Stein A. A source-free unsupervised domain adaptation method for cross-regional and cross-time crop mapping from satellite image time series[J]. *Remote Sensing of Environment*, 2024, 314: 114385.
- [33] Yang J Y, Hu Q, Li W, et al. An automated sample generation method by integrating phenology domain optical-SAR features in rice cropping pattern mapping[J]. *Remote Sensing of Environment*, 2024, 314: 114431.
- [34] 罗亚东, 段玉鹏, 武林森, 等. 联合自动样本生成与样本迁移的关中平原冬小麦识别[J]. *农业机械学报*, 2026, 57(10): 317–329.
- Luo Yadong, Duan Yupeng, Wu Linsen, et al. Identification of winter wheat in Guanzhong Plain based on combined automatic sample generation and sample migration[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2026, 57(10): 317–329. (in Chinese)