

# 基于HLS遥感数据与面向对象分割的农作物分类研究

朱 玲

哈尔滨师范大学地理科学学院, 黑龙江 哈尔滨

收稿日期: 2026年3月24日; 录用日期: 2026年4月16日; 发布日期: 2026年4月24日

## 摘 要

农作物分类是农业遥感研究的重要内容, 对于农业资源管理和作物种植结构监测具有重要意义。为提高农作物分类精度, 本文以黑龙江省七台河市茄子河区为研究区, 基于Sentinel-2光学遥感数据和HLS (Harmonized Landsat Sentinel) 遥感数据, 结合SNIC面向对象分割方法与随机森林分类算法, 对研究区主要农作物类型进行了识别与分类。首先对遥感影像进行云掩膜和预处理, 构建多时相NDVI等遥感特征, 并利用SNIC算法对影像进行超像素分割, 提取对象尺度特征; 随后基于随机森林模型进行农作物分类, 并通过混淆矩阵对分类结果进行精度评价。结果表明: 基于Sentinel-2光学遥感数据时, 基于像素方法和面向对象方法的总体精度分别为88.86%和90.39%, Kappa系数分别为0.8659和0.88, 面向对象方法在整体分类效果上略优于基于像素方法。在此基础上引入HLS多源遥感数据后, 分类总体精度进一步提高至92.55%, Kappa系数达到0.91, 其中水稻的识别精度提升最为明显。研究结果表明, 多源遥感数据融合能够提供更加丰富的时间序列信息, 而面向对象方法能够有效减少像素级噪声, 两者结合能够显著提升农作物分类精度。

## 关键词

农作物分类, Sentinel-2, HLS, 面向对象分类, 随机森林, 遥感

# Crop Classification Using HLS Remote Sensing Data and Object-Based Image Analysis

Ling Zhu

School of Geographical Sciences, Harbin Normal University, Harbin Heilongjiang

Received: March 24, 2026; accepted: April 16, 2026; published: April 24, 2026

## Abstract

Crop classification is an important topic in agricultural remote sensing and plays a significant role in agricultural resource management and crop planting structure monitoring. To improve classification accuracy, this study takes Qiezihe District of Qitaihe City, Heilongjiang Province, as the study area, and conducts crop classification based on Sentinel-2 optical remote sensing data and Harmonized Landsat Sentinel (HLS) data, combined with the SNIC object-based segmentation method and the random forest classification algorithm. First, cloud masking and preprocessing were applied to the remote sensing images, and multi-temporal features such as NDVI were constructed. Then, the SNIC algorithm was used to perform superpixel segmentation and extract object-level features. Subsequently, crop classification was carried out using a random forest model, and the classification results were evaluated using a confusion matrix. The results show that, based on Sentinel-2 data, the overall accuracies of pixel-based and object-based methods are 88.86% and 90.39%, with Kappa coefficients of 0.8659 and 0.88, respectively, indicating that the object-based method performs slightly better. After incorporating HLS multi-source data, the overall accuracy further increases to 92.55%, with a Kappa coefficient of 0.91, among which the classification accuracy of rice shows the most significant improvement. The results demonstrate that multi-source data fusion provides richer temporal information, while object-based methods effectively reduce pixel-level noise. Their combination can significantly improve crop classification accuracy.

## Keywords

Crop Classification, Sentinel-2, HLS, Object-Based Classification, Random Forest, Remote Sensing

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

农作物分类是农业遥感研究中的重要方向,对于作物生长状况监测、农业资源管理以及粮食产量预测具有重要意义。传统的田间测量效率低,需要投入大量人力,而遥感影像能够快速、准确地获取大范围农作物种植面积,并实时记录作物生长状况。随着遥感技术的不断发展, Sentinel-2A 卫星以其高空间分辨率(10 米)和丰富的多光谱波段(包括红边波段)在精细农业监测中得到广泛应用[1]-[3]。在农作物分类研究中,常用的方法主要包括基于像素(Pixel-Based)分类和面向对象(Object-Based)分类。基于像素的方法直接对影像的每个像素进行分类,简单易实现,但容易受到噪声和光谱异质性的影响,尤其在高分辨率影像中容易产生“椒盐”现象。相比之下,面向对象分类方法通过先进行影像分割,将相似像素聚合成对象,再基于对象的光谱、纹理和形状特征进行分类,能够更好地利用空间信息,提高分类精度,尤其适合复杂农田景观的识别[4]-[6]。

近年来,随着多源遥感数据融合的发展, HLS (Harmonized Landsat and Sentinel-2)数据集的出现为农作物分类提供了更高的时间分辨率和连续性[7]-[9]。HLS 将 Landsat-8 与 Sentinel-2 的影像进行了融合和时间序列校正,使得研究者可以在同一尺度上获取近乎每日的多光谱观测,从而更准确地捕捉作物生长周期的变化特征。这种高时间分辨率的数据尤其适用于基于时间序列的植被指数分析,如 NDVI、EVI 等,为分类算法提供了丰富的生长动态信息,同时也能显著提升面向对象分类的精度和稳定性。

## 2. 研究区概况与数据源

### 2.1. 研究区概况

茄子河区位于黑龙江省七台河市东部，具体位置如图 1 所示，地处三江平原向完达山低山丘陵过渡地带，地形以平原和缓丘为主，地势起伏较小，有利于大规模机械化耕作与农田连片布局。研究区属寒温带大陆性季风气候，四季分明，冬季寒冷漫长，夏季温暖湿润，无霜期适中，降水多集中在作物生长旺盛期，为春播秋收的一年一熟制农业生产提供了适宜的水热条件。作为东北地区典型的粮食主产区之一，该区耕地资源丰富，农业种植结构以水稻、玉米、大豆为主，作物物候规律明显，生长节律较为同步，使其在遥感影像中呈现出时序特征清晰、地块边界规整的特点。上述自然地理与农业生产特征，为开展基于时序遥感数据的农作物精细识别研究提供了理想的条件支撑。

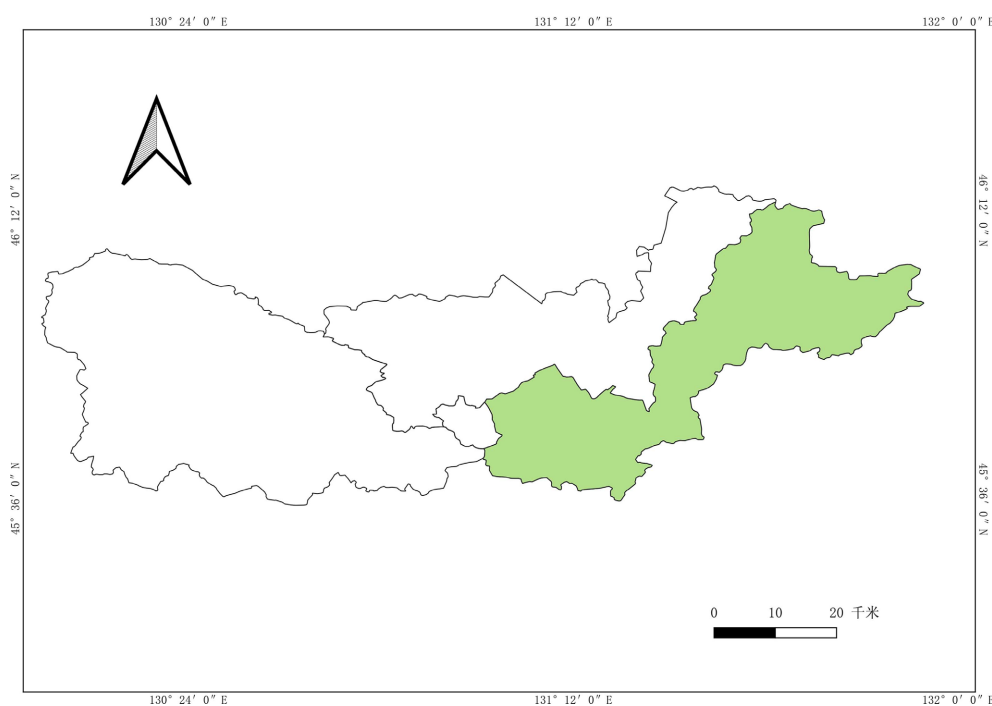


Figure 1. Location of the study area in Qiezihe district

图 1. 茄子河区研究区位置

### 2.2. 数据来源

#### 2.2.1. 遥感数据

本研究所用的遥感数据主要包括 Sentinel-2 和 Harmonized Landsat and Sentinel-2 (HLS)数据集。Sentinel-2 卫星系列由欧洲航天局(ESA)为满足哥白尼计划任务而开发，Sentinel-2A 于 2015 年 6 月 23 日发射，搭载多光谱成像仪(MSI)，可获取 13 个波段，其中 B2、B3、B4、B8 的空间分辨率为 10 m，B5、B6、B7、B8A、B11、B12 为 20 m，B1、B9、B10 为 60 m，具体波段信息如表 1 所示。两颗卫星协同工作，实现约 5 天的重访周期[10]。本研究选用 Sentinel-2L2A 级数据(已进行大气校正)，时间范围为 2020 年 7 月 15 日至 2020 年 8 月 31 日，云量  $\leq 30\%$ 。

HLS 数据由 NASA 提供，通过融合 Landsat 8 OLI/TIRS 与 Sentinel-2A/B 影像生成，经过统一的几何校正、辐射定标及大气校正处理，生成空间分辨率约为 30 m 的表面反射率影像，并提供近乎日频的时间

序列观测，覆盖全球陆地区域，可广泛应用于植被监测、农作物分类及生态环境变化研究。

在本研究中，选取 2020 年 6 月至 10 月的 HLS L30 (Landsat 8)与 S30 (Sentinel-2)影像覆盖茄子河研究区。为保证影像质量，对原始影像进行了云与阴影掩膜处理，并计算 NDVI、EVI 等植被指数，构建多时相遥感特征数据，为后续农作物分类提供基础数据。

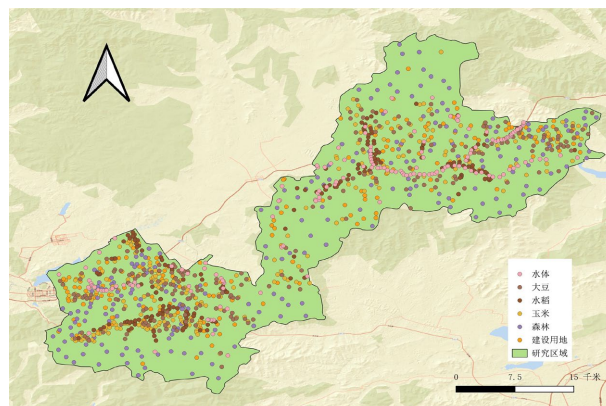
**Table 1.** Sentinel-2 band information

**表 1.** Sentinel-2 波段信息

波段	波段名称	英文名称	Sentinel-2A 中心 波长(nm)	带宽(nm)	空间分辨率(米)
B1	沿海气溶胶	Coastal aerosol	443.9	20	60
B2	蓝光	Blue	496.6	65	10
B3	绿光	Green	560.0	35	10
B4	红光	Red	664.5	30	10
B5	植被红边 1	Vegetation Red Edge	703.9	15	20
B6	植被红边 2	Vegetation Red Edge	740.2	15	20
B7	植被红边 3	Vegetation Red Edge	782.5	20	20
B8	近红(宽)	NIR (Near Infrared)	835.1	115	10
B8A	近红(窄)	Narrow NIR	864.8	20	20
B9	水汽	Water Vapour	945.0	20	60
B10	云检测	SWIR-Cirrus	1373.5	30	60
B11	短波红外 1	SWIR	1613.7	90	20
B12	短波红外 2	SWIR	2202.4	180	20

### 2.2.2. 样本数据

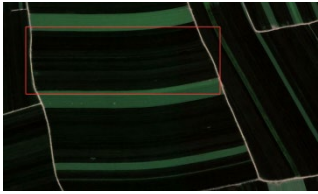
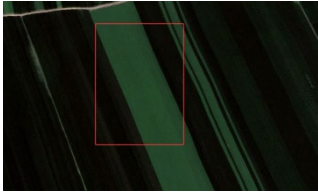

本研究选取了研究区内三类主要粮食作物作为样本，包括大豆、水稻和玉米。所有样本均基于 Google Earth 高分辨率影像，通过目视解译方式进行标注，其中大豆样本 218 个，水稻样本 187 个，玉米样本 232 个。各类作物样本数量较为均衡，能够较好地代表研究区内主要作物的空间分布特征，为后续分类模型训练和精度评估提供可靠的基础。样本数据按照 7:3 的比例随机划分为训练集和验证集，其中 70%用于模型训练，30%用于精度验证。采用随机划分方式能够保证样本分布的均匀性，从而提高模型评估结果的可靠性。样本的空间分布情况见图 2，高分辨率影像示例见表 2。



**Figure 2.** Distribution of sample points

**图 2.** 样本点分布

**Table 2.** High-resolution images of sample points**表 2.** 样本点高清影像

土地覆被类型	示例图像	特征描述
玉米		玉米地块一般具有整齐的行列结构，叶色深绿，常与大豆交替种植。
大豆		大豆种植区域纹理较细腻，颜色较浅，常见于与玉米相邻地块。
水稻		水稻多分布在低洼、平坦、易灌溉区域，田块规则、有明显水网格局。

### 3. 研究方法

#### 3.1. 技术路线

本文的技术路线如图 3 所示，主要包括数据采集与预处理、特征构建、影像分割、样本划分、随机森林分类与精度验证、专题制图等环节。在数据采集与预处理阶段，以 Sentinel-2 和 Landsat 8/9 OLI 影像为主要遥感数据源，结合 Google Earth 高分辨率影像与实地样本点数据，对获取的遥感影像进行裁剪、去云和融合处理，生成 HLS 数据集。在特征构建阶段，基于 Sentinel-2 影像提取 B1 至 B12 共 12 个光谱波段，并计算 6 月、7 月、8 月、9 月的归一化植被指数，构建时序光谱特征集。随后，采用 SNIC 非迭代超像素分割算法对影像进行分割，生成均质对象单元。结合样本点数据与目视解译结果，将分割后的对象划分为训练集和验证集。基于训练样本构建随机森林分类模型，对研究区农作物类型进行识别，并利用验证样本对分类结果进行精度评价，最后生成 2020 年七台河市农作物分布专题图。

#### 3.2. SNIC 非迭代超像素分割

SNIC (Simple Non-Iterative Clustering) 非迭代超像素分割是一种常用于遥感影像面向对象分析的图像分割方法。该算法在 SLIC (Simple Linear Iterative Clustering) 算法基础上进行改进，通过区域生长方式将光谱特征相似且空间上相邻的像素聚合为具有一定空间连续性的超像素对象，从而实现影像的对象化表达。通过超像素分割，可以有效减少像素级分类中常见的“椒盐现象”，使地物边界更加清晰，并为后续面向对象分类提供稳定的对象特征。SNIC 的分割效果主要由超像素尺度(Size)、紧凑度(Compactness)、空间连通性(Connectivity)以及邻域/种子参数共同决定[11]。本研究首先利用 seedGrid (10)生成规则分布的初始种子点；在此基础上设置 size 为 13 以控制超像素尺度，compactness 为 0 以增强光谱主导作用，connectivity 为 4 以保证四邻域连通，neighborhoodSize 为 64 以扩大区域生长范围。基于上述参数，采用

SNIC 对多源遥感特征影像进行分割, 并计算各分割对象内波段及遥感指数的均值, 构建对象级特征, 结合样本数据训练随机森林分类器, 实现面向对象的农作物分类识别。

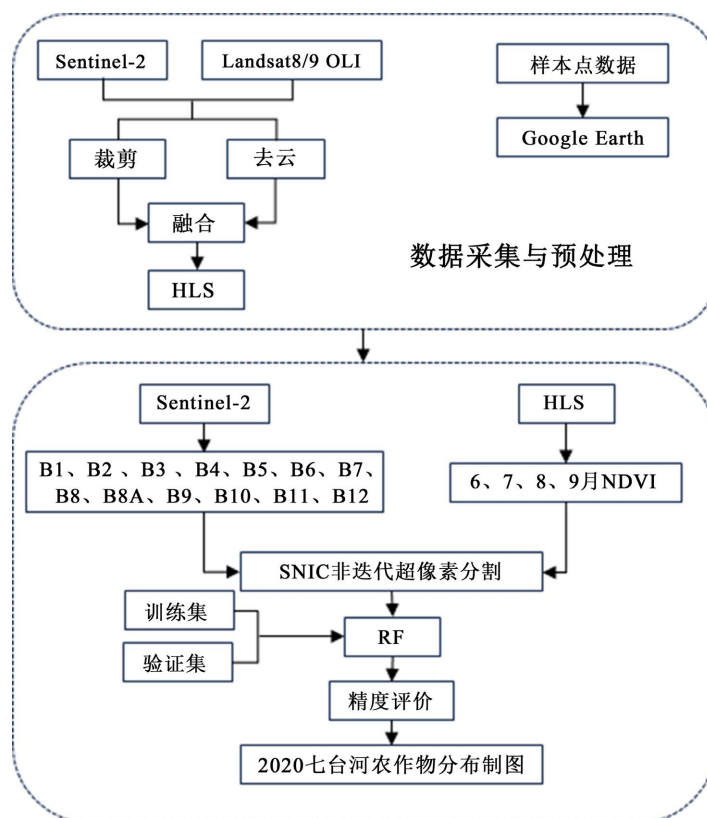


Figure 3. Technical flowchart  
图3. 技术路线

### 3.3. 随机森林分类

随机森林(Random Forest, RF)是一种基于集成学习思想的监督分类算法, 由多棵决策树构成, 通过对多个决策树分类结果进行投票来确定最终分类结果。该算法在训练过程中采用 Bootstrap 自助采样方法从原始样本集中随机抽取子样本构建训练集, 并在每个节点分裂时随机选择部分特征进行最优划分, 从而生成多棵相互独立的决策树。最终分类结果由所有决策树的预测结果通过多数投票方式确定[12][13]。由于引入了样本随机性和特征随机性, 随机森林能够有效降低单棵决策树过拟合的问题, 具有较强的泛化能力。同时, 该算法对数据分布要求较低, 能够处理高维数据, 并对噪声和异常值具有较好的鲁棒性, 相比支持向量机, 其计算效率更高且参数调节相对简便, 因此在遥感影像分类领域得到了广泛应用。随机森林分类器的关键参数设置如下: 决策树数量设为 150, 以在保证计算效率的同时提高模型稳定性。

### 3.4. 精度评价

为了评估分类模型的性能与分类结果的可靠性, 本文对模型输出结果进行了精度评价。通过对比分类结果与样本数据之间的一致性, 采用混淆矩阵(Confusion Matrix)及其派生指标进行定量分析, 包括总体精度(Overall Accuracy, OA)、用户精度(User's Accuracy)、生产者精度(Producer's Accuracy)和 Kappa 系数[14]。具体计算公式如下:

$$\begin{aligned}
 UA &= \frac{n_{ii}}{\sum_{j=1}^k n_{ji}} \times 100\% \\
 PA &= \frac{n_{ii}}{\sum_{j=1}^k n_{ij}} \times 100\% \\
 OA &= \frac{\sum_{i=1}^k n_{ii}}{N} \times 100\% \\
 \text{Kappa} &= \frac{\left[ n \cdot \sum_{i=1}^k n_{ii} - \sum_{i=1}^k (n_{ji} \cdot n_{ij}) \right]}{\left[ N^2 - \sum_{i=1}^k (n_{ji} \cdot n_{ij}) \right]}
 \end{aligned}$$

式中,  $n_{ii}$  代表第  $i$  类的正确分类数,  $n_{ji}$  代表实际类别为第  $j$  类, 预测结果为第  $i$  类的样本数量,  $n_{ij}$  代表实际类别为第  $i$  类, 预测结果为第  $j$  类的样本数量,  $k$  代表类别总数,  $N$  代表样本总数。

### 3.5. 时序 NDVI 构建

本研究利用 HLS (Harmonized Landsat Sentinel) 融合数据构建多时相 NDVI 特征。首先在 Google Earth Engine 平台获取 HL30 (Landsat 8) 和 HLSS30 (Sentinel-2) 影像, 并将两类影像进行合并, 筛选 2020 年 6 月至 10 月覆盖研究区的影像数据。随后利用影像中的 Fmask 质量波段进行云、云阴影及雪等像元的掩膜处理, 并对影像反射率进行比例缩放处理, 以获得标准化的地表反射率数据。

在此基础上, 根据不同传感器的波段设置计算 NDVI。对于 Sentinel-2 数据, 利用近红外波段 B8A 与红光波段 B4 计算 NDVI; 对于 Landsat 8 数据, 则利用近红外波段 B5 与红光波段 B4 计算 NDVI, 从而保证不同数据源之间的指数一致性。NDVI 的计算公式为:

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}}$$

为了反映作物在生长季内的时序变化特征, 进一步按月份对 NDVI 进行统计, 分别计算 2020 年 6 月、7 月、8 月和 9 月的月均 NDVI, 变化曲线如图 4 所示, 并将其合成为多波段影像 (NDVI\_6、NDVI\_7、NDVI\_8、NDVI\_9)。这些多时相 NDVI 特征能够有效反映不同作物在生长季内的物候差异, 为后续农作物分类提供重要的时间序列信息。




Figure 4. NDVI variation curves from June to September  
图 4. 6~9 月 NDVI 变化曲线

## 4. 结果与分析

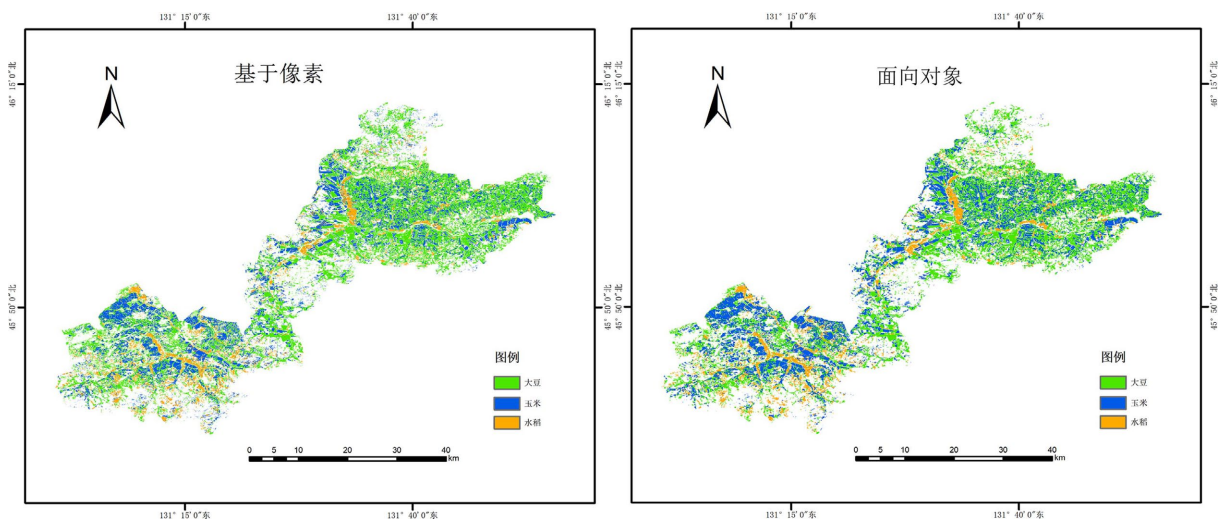
### 4.1. 基于光学遥感分类结果

为了评价基于光学遥感数据的农作物分类效果，利用验证样本构建混淆矩阵，并计算生产者精度(Producer's Accuracy, PA)、用户精度(User's Accuracy, UA)、总体精度(Overall Accuracy)以及 Kappa 系数等指标，对分类结果进行定量评价。不同方法下主要作物类型的分类精度统计结果如表 3 所示，作物分布如图 5 所示。

**Table 3.** Classification accuracy based on pixel-based and object-based methods

**表 3.** 基于像素与面向对象分类精度

	基于像素		面向对象	
	PA	UA	PA	UA
大豆	95.38%	87.32%	98.46%	94.12%
玉米	85.92%	92.42%	98.51%	90.41%
水稻	82.46%	85.45%	77.78%	89.36%
总体精度	88.86%		90.39%	
kappa 系数	86.59%		0.88	



**Figure 5.** Crop distribution based on pixel-based and object-based methods

**图 5.** 基于像素与面向对象农作物分布

由表 3 可知，两种方法均能够较好地识别研究区的主要农作物类型。其中，基于像素方法的总体精度为 88.86%，Kappa 系数为 0.8659；面向对象方法的总体精度为 90.39%，Kappa 系数为 0.88。总体来看，两种方法的分类精度均处于较高水平，能够较为准确地反映研究区主要作物的空间分布情况，但面向对象方法在总体精度上略优于基于像素方法，说明在高分辨率遥感影像中，引入对象尺度信息有助于提升分类效果。

从不同作物类型的分类精度来看，大豆在两种方法下均取得了较好的识别效果。其中，基于像素方法的大豆生产者精度为 95.38%，用户精度为 87.32%；而面向对象方法的大豆生产者精度提高至 98.46%，

用户精度达到 94.12%，说明通过影像分割形成的对象能够更好地表达大豆地块的空间特征，从而提升分类准确性。玉米的分类精度同样较高，基于像素方法的生产者精度和用户精度分别为 85.92%和 92.42%，而在面向对象方法下，生产者精度提高至 98.51%，但用户精度略降至 90.41%，表明部分其他地物可能被误分为玉米，从而导致用户精度略有下降。相比之下，水稻的分类精度相对较低。基于像素方法下，水稻的生产者精度和用户精度分别为 82.46%和 85.45%；而在面向对象方法下，生产者精度为 77.78%，用户精度为 89.36%。这一结果表明，在研究区内水稻与其他作物在某些生长阶段可能具有相似的光谱特征，从而在分类过程中产生一定程度的混分现象。

两种方法均能够较好地完成研究区农作物分类任务，其中面向对象方法在总体精度及大豆、玉米识别方面表现更优，而基于像素方法在部分作物类别上仍具有一定稳定性。结合多时相遥感特征信息，可以进一步增强不同作物之间的区分能力，为区域农作物种植结构监测提供可靠的数据支持。

#### 4.2. 基于 HLS 数据与面向对象方法的分类结果

在基于面向对象方法的基础上，对仅使用 Sentinel-2 影像的分类结果与使用 Sentinel-2 和 HLS 的分类结果进行比较，结果如表 4 所示，作物分布如图 6 所示。

**Table 4.** Accuracy comparison before and after incorporating HLS data based on object-based method

**表 4.** 基于面向对象方法引入 HLS 数据前后精度对比

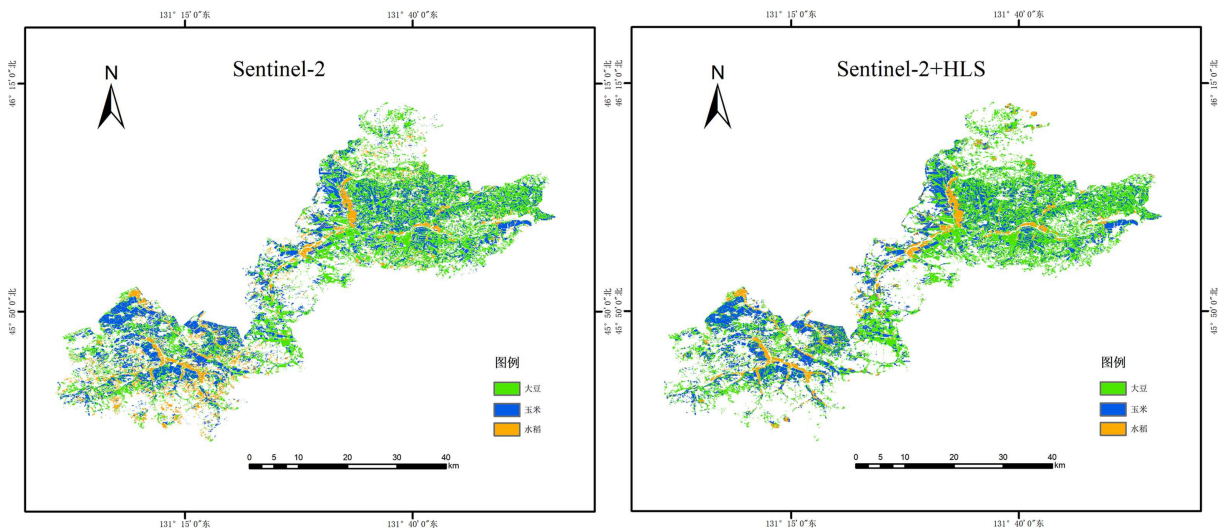
	Sentinel-2		Sentinel-2 + HLS	
	PA	UA	PA	UA
大豆	98.46%	94.12%	90.77%	96.72%
玉米	98.51%	90.41%	95.45%	95.45%
水稻	77.78%	89.36%	96.36%	89.83%
总体精度	90.39%		92.55%	
kappa 系数	0.88		0.91	

从总体来看，融合 HLS 数据后分类效果明显提升，总体精度从单源 Sentinel-2 的 90.39%提高至 92.55%，Kappa 系数由 0.88 上升至 0.91，表明多时相 HLS 数据能够提供丰富的时间序列信息，增强作物的光谱表征能力，从而提高分类的可靠性和稳定性。

从单类作物的分类表现来看，大豆在单源 Sentinel-2 数据下的生产者精度(PA)为 98.46%，用户精度(UA)为 94.12%，引入 HLS 数据后，PA 略下降至 90.77%，但 UA 提升至 96.72%，显示被判定为大豆的像素中真正大豆比例增加，分类的可靠性有所增强。玉米在单源 Sentinel-2 下的 PA 为 98.51%，UA 为 90.41%，融合 HLS 数据后，PA 和 UA 均提升至 95.45%，说明 HLS 的时序信息可以更准确地捕捉玉米生长周期的光谱变化，减少误分类。水稻的识别效果提升最为明显，单源 Sentinel-2 下 PA 仅为 77.78%，而 UA 为 89.36%；加入 HLS 后，PA 大幅提高至 96.36%，UA 保持在 89.83%，显示高时间分辨率数据对水稻在生长季节的光谱特征捕捉能力显著，尤其在水田湿润条件下，NDVI 等植被指数的时间序列变化更易区分水稻与其他作物。

HLS 数据的引入在面向对象分类中发挥了重要作用。一方面，多时相影像能够增强作物生长周期特征的代表能力，使得光谱相似但生长期不同的作物更加容易区分；另一方面，面向对象方法通过超像素分割将影像划分为相对均质的对象，降低了像素级噪声的影响，使分类结果在空间上更加连续、真实。尽管大豆的 PA 略有下降，但整体上，结合 HLS 数据的面向对象方法能够有效提升作物分类的精度和可

靠性，尤其对水稻和玉米等时序敏感作物的识别效果最为显著，为高精度农作物分类提供了有效的数据和方法支撑。

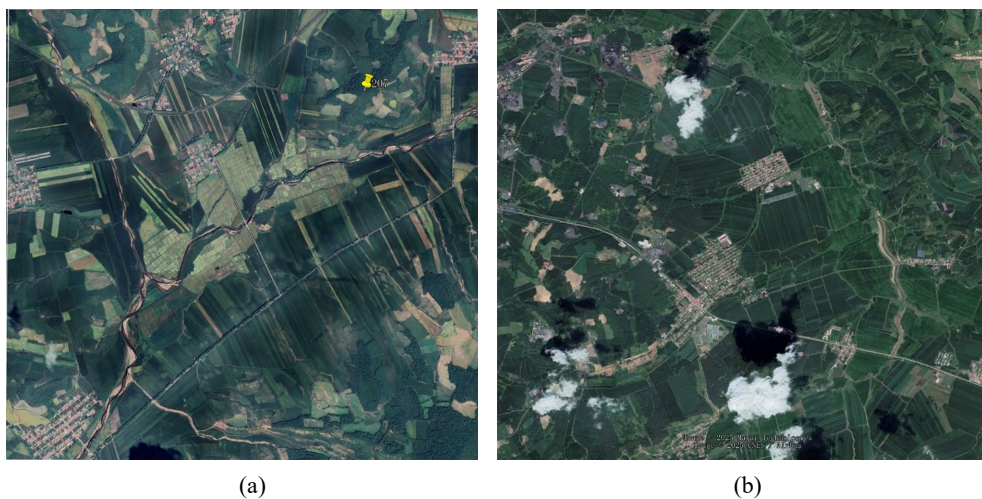


**Figure 6.** Crop distribution maps before and after incorporating HLS data  
**图 6.** 引入 HLS 数据前后作物分布图

## 5. 分析讨论

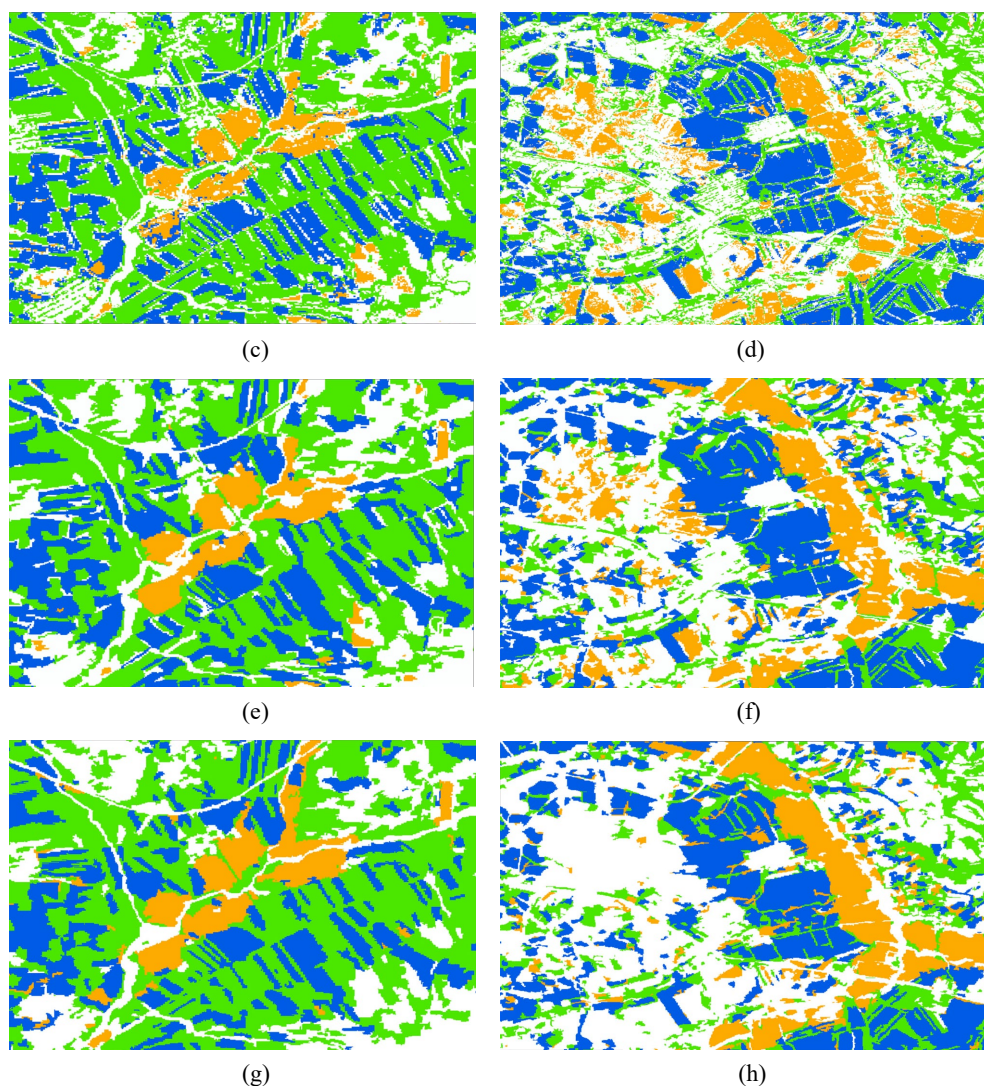
在局部区域尺度上，为进一步分析不同方法在空间表达上的差异，选取研究区内两个典型区域进行对比分析，如图 7(a)~(h)所示。区域 1 与区域 2 均包含水稻、玉米和大豆等多种作物类型，地块边界较为复杂，能够较好地反映不同分类方法的表现差异。

从区域 1 的分类结果来看，基于像素的方法在空间上存在较为明显的“椒盐现象”，同一地块内部出现较多零散像元，导致地块内部分类不够连续(图 7(c))。相比之下，面向对象方法通过 SNIC 分割将影像划分为均质对象单元，在分类过程中能够充分利用对象内部的光谱与空间信息，使同一农田地块的分类结果更加完整连续，地块边界也更加清晰(图 7(e))。然而，在部分地块边缘区域仍然存在少量误分现象，这可能与分割尺度设置以及不同作物光谱特征相似有关。在融合 HLS 数据后，分类结果在空间结构上进



(a)

(b)



**Figure 7.** Comparison of local details of crop distribution. (a) (b) Ground truth images; (c) (d) Pixel-based classification results using Sentinel-2 imagery; (e)~(f) Object-based classification results using Sentinel-2 imagery; (g) (h) Object-based classification results after integrating HLS data

**图 7.** 作物分布局部细节对比图。(a) (b) 地面真实影像；(c) (d) 基于 Sentinel-2 影像的像素级分类结果；(e)~(f) 基于 Sentinel-2 影像的面向对象分类结果；(g) (h) 融合 HLS 数据后的面向对象分类结果

一步得到改善(图 7(g))。由于 HLS 数据提供了更高时间分辨率的多时相信息，使模型能够更好地捕捉不同作物在生长季中的物候变化特征，从而减少不同作物之间的混分现象。从图中可以看出，原本在单源 Sentinel-2 分类中存在误分的部分地块，在融合 HLS 数据后得到明显修正，分类结果与真实地块分布更加一致。

区域 2 的对比结果同样表明，基于像素方法虽然在整体精度上较高，但在空间表达上仍然存在较多离散像元(图 7(d))。面向对象方法能够有效减少这种噪声，使分类结果更加平滑(图 7(f))。当引入 HLS 多时相数据后(图 7(h))，部分原本难以区分的地块被正确识别，尤其是在水稻种植区域，分类结果与真实地块分布更加吻合，说明多时相信息对于区分物候差异明显的作物具有重要作用。

通过典型区域的对比可以发现，面向对象方法在空间连续性和地块完整性方面具有明显优势，而多源遥感数据融合则能够在时间维度上增强作物特征表达能力。二者结合能够有效提升农作物分类的空间

表现效果, 使分类结果更加接近真实农田格局。

## 6. 结论

本文以黑龙江省七台河市茄子河区为研究区, 基于 Sentinel-2 光学遥感数据与 HLS (Harmonized Landsat Sentinel) 多源遥感数据, 结合 SNIC 面向对象分割方法与随机森林分类算法, 对研究区主要农作物类型进行了识别与分类, 并对不同数据源及分类方法的效果进行了比较分析。研究表明, 利用 Sentinel-2 光学遥感数据能够较好地实现研究区主要农作物的分类识别, 其中基于像素方法和面向对象方法的总体精度分别达到 88.86% 和 90.39%, Kappa 系数分别为 0.8659 和 0.88, 两种方法均能够较为准确地反映研究区农作物的空间分布特征。相比之下, 面向对象方法在总体精度上略优于基于像素方法, 说明通过影像分割构建对象单元能够在一定程度上减少像素级噪声, 提高分类结果的空间一致性。

从不同作物类型的分类效果来看, 大豆和玉米的识别精度整体较高, 而水稻的分类精度相对较低。这主要与不同作物在部分生长阶段具有相似的光谱特征有关, 从而在分类过程中容易产生混分现象。同时, 面向对象方法在大豆和玉米的识别方面表现出较高的生产者精度, 说明该方法能够更好地利用地块尺度信息, 提高作物识别能力。

在面向对象分类基础上进一步引入 HLS 多源遥感数据后, 分类精度得到进一步提升, 总体精度提高至 92.55%, Kappa 系数达到 0.91。多时相 HLS 数据能够提供更加连续的遥感观测信息, 通过 NDVI 等植被指数的时间序列特征可以有效反映作物生长过程中的物候变化规律, 从而增强不同作物之间的区分能力, 其中水稻的识别精度提升最为明显。研究表明, 多源遥感数据融合与面向对象分类方法相结合能够有效提高农作物分类的精度和稳定性。

基于多源遥感数据与面向对象分割方法的农作物分类能够较为准确地获取研究区农作物空间分布信息, 为区域农业资源调查和农作物种植结构监测提供了有效的技术手段。未来研究可进一步结合更高空间分辨率影像、更多时序特征以及深度学习方法, 以进一步提升农作物分类的精度和应用潜力。

## 参考文献

- [1] Hoel, C., Wolff, K. and Laine, L. (2018) Automated Speed and Lane Change Decision Making Using Deep Reinforcement Learning. 2018 21st International Conference on Intelligent Transportation Systems (ITSC), Maui, 4-7 November 2018, 2148-2155. <https://doi.org/10.1109/itsc.2018.8569568>
- [2] 薛宇飞, 等. 基于 Sentinel-2 遥感影像的烟草种植信息精准提取[J]. 中国烟草科学, 2022, 43(1): 96-106.
- [3] 祁向前, 孙德浩, 贾连星. 哨兵 2 号多时相植被指数作物分类及监测[J]. 测绘工程, 2022, 31(6): 47-53.
- [4] 汤永康, 张振宏, 杨可, 等. 基于时序 Sentinel-2 影像的阿拉善左旗作物种植结构分析[J]. 农业技术与装备, 2025(8): 136-138.
- [5] 蒙方鑫, 覃先林, 黄水生, 等. 多对象特征融合的海南特色经济作物分类方法[J]. 测绘科学, 2025, 50(7): 171-183.
- [6] 李红霞, 石云, 丁中杰, 等. 结合多源遥感数据和面向对象的旱区湿地信息提取[J]. 环境科学, 2025, 46(5): 3127-3138.
- [7] Park, S., Kang, S., Hwang, B. and Ko, D.W. (2025) Detecting Abandoned Cropland in Monsoon-Influenced Regions Using HLS Imagery and Interpretable Machine Learning. *Agronomy*, **15**, Article 2702. <https://doi.org/10.3390/agronomy15122702>
- [8] Zhang, H.K., Shen, Y., Zhang, X., Li, J., Yang, Z., Xu, Y., et al. (2025) Robust and Timely Within-Season Conterminous United States Crop Type Mapping Using Landsat Sentinel-2 Time Series and the Transformer Architecture. *Remote Sensing of Environment*, **329**, Article ID: 114950. <https://doi.org/10.1016/j.rse.2025.114950>
- [9] Aires, U.R.V., Martins, V.S., Ferreira, L.B., Huang, Y., Heintzman, L. and Ouyang, Y. (2025) Impact of Sampling Techniques on Crop Type Mapping Using Multi-Temporal Composites from Harmonized Landsat-Sentinel Images. *Computers and Electronics in Agriculture*, **237**, Article ID: 110676. <https://doi.org/10.1016/j.compag.2025.110676>
- [10] Xia, T., Ji, W., Li, W., Zhang, C. and Wu, W. (2021) Phenology-Based Decision Tree Classification of Rice-Crayfish Fields from Sentinel-2 Imagery in Qianjiang, China. *International Journal of Remote Sensing*, **42**, 8124-8144.

---

<https://doi.org/10.1080/01431161.2021.1973687>

- [11] 闫明, 庞勇, 何云玲, 等. 基于 GEE 云平台和 Sentinel-2 数据的普洱市森林覆盖制图[J]. 遥感技术与应用, 2023, 38(2): 432-442.
- [12] 韩东枫, 李峰, 秦泉, 等. 基于 GEE 和 Sentinel-1/2 数据的夏玉米种植面积精细化识别方法[J]. 海洋气象学报, 2024, 44(3): 122-132.
- [13] Rhodes, J.S., Cutler, A. and Moon, K.R. (2023) Geometry- and Accuracy-Preserving Random Forest Proximities. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **45**, 10947-10959. <https://doi.org/10.1109/tpami.2023.3263774>
- [14] Congalton, R.G. (1991) A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment*, **37**, 35-46. [https://doi.org/10.1016/0034-4257\(91\)90048-b](https://doi.org/10.1016/0034-4257(91)90048-b)