

协同利用卫星与无人机影像的田块尺度水稻NDVI连续监测

任紫晗¹, 徐嘉淇¹, 魏珊珊², 吴文斌¹, 李文娟¹

1. 中国农业科学院农业资源与农业区划研究所 北方干旱半干旱耕地高效利用全国重点实验室, 北京 100081;

2. 新加坡国立大学遥感成像、传感与处理中心, 新加坡 119076

摘要: 田块尺度作物长势的实时监测是精准农业的关键。然而, 卫星遥感监测范围广但易受天气与空间分辨率制约, 无人机 (unmanned aerial vehicle, UAV) 空间分辨率高但受续航限制, 单一数据源难以满足大范围连续监测的需求。针对此问题, 本研究基于 UAV、Sentinel-2 与 PlanetScope SuperDove 多光谱数据, 提出一种基于改进 CACAO 算法的跨平台时空融合方法。该方法构建了“UAV+Sentinel-2”与“SuperDove+Sentinel-2+UAV”两种数据组合策略, 并通过前向预测与后向更新两种模式, 近实时地生成每日 1 米分辨率的归一化植被指数 (NDVI) 时间序列数据集。进一步采用留一法交叉验证 (Leave-One-Out Cross-Validation, LOOCV), 并与现有 GLM-STF (基于广义线性模型的时空融合, Generalized Linear Model-based Spatiotemporal Fusion) 算法进行对比, 以评估融合结果的精度。结果表明: (1) 不同平台的 NDVI 数据具有良好的一致性, Sentinel-2 与 SuperDove NDVI 相关性达到 0.97, 无人机与卫星 NDVI 相关性超过 0.75, 满足数据融合的前提; (2) CACAO 算法能够有效地重建水稻的物候动态, 其中后向更新模式生成的 NDVI 时间序列更为平滑, 且基于 CACAO 的两种数据组合策略均获得了较高的精度 ($R > 0.94$), 在关键物候期引入高时间分辨率的 SuperDove 数据能在一定程度上提升精度, 相关性从 0.51 提升至 0.67; (3) CACAO 算法在整个生长季中表现出比 GLM-STF 算法更稳定和略高的精度优势。综上所述, 本研究提出的跨平台融合框架能够有效生成连续、高精度的田块尺度水稻 NDVI 时间序列, 可以为作物长势的精细化监测与精准化管理提供有力的技术支持。

关键词: PlanetScope, 哨兵二号 (Sentinel-2), 时空数据融合, 长势监测, 精准农业, 田块尺度, 物候曲线, 近实时监测

中图分类号: P2

引用格式: 任紫晗, 徐嘉淇, 魏珊珊, 吴文斌, 李文娟. XXXX. 协同利用卫星与无人机影像的田块尺度水稻 NDVI 连续监测. 遥感学报, XX(XX): 1-20

REN Zihan, XU Jiaqi, WEI Shanshan, WU Wenbin, LI Wenjuan. XXXX. Synergistic use of satellite and UAV imagery for continuous monitoring of field-scale paddy rice NDVI. National Remote Sensing Bulletin, DOI:10.11834/jrs.20265479]

1 引言

联合国粮食及农业组织 (FAO) 指出, 当前“零饥饿”可持续发展目标 (SDG 2) 的实施进度明显滞后 (Sporchia 等, 2024; Unicef, 2024), 全球粮食安全形势日趋严峻。因此, 构建高效的粮食生产监测体系至关重要 (Zhao 等, 2020)。水稻作为全球半数以上人口的主要粮食作物, 提供了超过 20% 的热量摄入 (Bouvet 和 Le Toan,

2011)。实现水稻长势的实时精准监测, 不仅可为稻田精准管理提供关键数据支撑, 也对保障粮食安全、推动农业可持续发展具有重要意义 (赵柄婷等, 2025)。然而, 传统人工调查方法耗时费力、主观性强, 难以有效捕捉水稻长势的快速动态变化, 无法满足现代精准农业的需求 (王伟康等, 2023)。近年来, 卫星与无人机遥感技术的发展为作物生长监测提供了新的解决路径 (Beerli 和 Peled, 2009)。通过利用遥感数据的近红外等对

收稿日期: 2025-11-17; 预印本: 2026-03-13

基金项目: 国家重点研发计划 (编号: 2023YFD2300500)

第一作者简介: 任紫晗, 研究方向为农业遥感。E-mail: zihanren2001@163.com

通信作者简介: 李文娟, 研究方向为基于空天地多源遥感技术的农田智能监测技术及应用。E-mail: liwenjuan01@caas.cn

作物生理状态敏感的关键波段,可以有效捕捉作物长势的动态变化(林维潘等, 2020),从而为作物长势动态监测与精准农业管理提供技术支撑(Yuan等, 2025)。

目前大范围作物生长监测多依赖光学卫星遥感(Xu等, 2024; Gao等, 2017),如Landsat、MODIS、Sentinel-2和GF-6等(Jiang等, 2021; Dong等, 2016; 姜轶峰等, 2025; 王俊等, 2025)。它们通常具备覆盖面积大、支持周期性监测的优点,但其空间分辨率有限,且易受云雨天气影响(Gevaert等, 2015; 柳文杰等, 2018),难以实现田块尺度的作物长势实时精准监测。无人机遥感虽具较好的灵活性和高空间分辨率(王宇唯等, 2024),可捕捉田块内部作物细节变化,但其续航能力不足,单次覆盖面积有限,难以实现大范围连续监测(Pajares, 2015)。

近年来,时空融合技术的不断发展与应用,为获取兼具高空间与高时间分辨率的数据提供了有效途径。时空融合方法通过融合低空间分辨率高频影像与高空间分辨率低频影像,生成高时空分辨率序列数据,从而实现作物生长的连续精准监测(Kukunuri和Singh, 2022; Jin等, 2021)。迄今为止,针对遥感数据时空融合算法已开展了大量研究,发展了多种方法,包括基于分解的方法、基于权重函数的方法、基于贝叶斯的方法、基于学习的方法以及混合方法等(刘建波等, 2016; 杨军明等, 2019; Zhu等, 2018)。其中,时空自适应反射率融合算法(STARFM)应用较为广泛(Gao等, 2006),该算法依据光谱差异、时间差异和空间距离对邻近像素进行加权,使用经验方式重建每日高空间分辨率反射率数据。为进一步提升融合精度,后续研究在STARFM基础上发展出多种改进算法(Zhu等, 2010; Weng等, 2014; Hilker等, 2009)。然而,此类模型通常要求已知日期和预测日期之间土地覆盖类型基本保持不变,在实际应用中存在一定的局限性。此外,也有学者提出时空形状匹配模型(Zhang等, 2021),即通过融合每日低空间分辨率影像的时间曲线与观测频次较低的高空间分辨率影像的时间曲线,来生成高时空分辨率的影像时间序列。Sun等(2021)利用MODIS观测数据中提取的作物参考曲线,建立了一种时间序列数据融合方法,生成了一个完整的30m分辨率的NDVI时间序列。

Verger等(2013)考虑物候特征,提出了CACAO(Consistent Adjustment of the Climatology to Actual Observations)方法,为每个像元构建物候变化曲线,通过对其进行缩放和平移实现对高分辨率观测数据的最佳拟合,成功重建了可以准确反映植被动态变化的长时间序列数据集。

尽管目前已经对时空数据融合算法展开了大量的研究,但现有算法主要集中于不同卫星传感器之间的融合(宋杰等, 2024; Liu等, 2024),在无人机与卫星遥感数据等跨平台数据融合的适用性研究仍较为欠缺。此外,尽管针对植被指数(如NDVI)的时间序列重建,在区域与全球尺度的研究已相对成熟,但针对田块尺度上,如何构建覆盖作物关键生长期的高时空分辨率数据集,现有研究仍显不足。因此当前方法难以有效捕捉田间作物快速变化的生理过程与细微长势差异,在一定程度上限制了时空融合技术在田块尺度作物长势精准监测中的应用潜力。

NDVI是监测作物健康和生物物理参数最广泛使用且最有效的植被指数之一(Zeng等, 2022)。对于作物而言,NDVI广泛应用于监测作物物候(Seo等, 2019)、作物生长阶段(Gao等, 2020)、预测作物产量(Sun等, 2017)等方面,这些应用的实现通常依赖于连续的NDVI时间序列数据。目前,大范围的连续植被动态监测主要依赖于多源卫星遥感产品。MODIS和AVHRR提供了长期的全球覆盖NDVI数据集,被广泛用于大尺度物候与植被生产力研究(Zhang等, 2003; Tucker等, 2005)。近年来,通过数据融合计划,产生了如Harmonized Landsat and Sentinel-2(HLS)等具有更高时空分辨率的产品,提升了生成中高分辨率、连续NDVI时间序列的能力(Claverie等, 2018)。然而,在面向田块尺度的精准农业管理(如施肥、病虫害防治)时,现有产品在空间分辨率与时间分辨率上仍面临双重制约:粗空间分辨率产品受混合像元效应影响严重,无法准确反映田块内部的长势空间异质性(Gao等, 2017);而中高分辨率产品(10–30 m分辨率)虽能识别田块边界,但其有效观测频次受卫星重访周期与云层干扰的严重制约,在农作物关键生长阶段难以获取连续的日尺度观测数据,无法满足实时农情监测与决策的需求(Zhu等, 2022)。

因此,为实现田块尺度水稻生长的高精度、

连续动态监测，本研究提出一种协同利用 UAV 与多源卫星（Sentinel-2、PlanetScope）数据的跨平台时空融合框架。本研究首先对不同平台间 NDVI 数据的一致性进行分析。在此基础上，通过构建 CACAO 时空融合算法，生成每日 1 米分辨率的水稻 NDVI 时间序列数据，并使用留一法交叉验证以及 GLM-STF 算法进行对比，对本研究提出的算法精度和不确定因素进行评价和讨论。

2 研究区与数据来源

2.1 研究区概况

研究区位于天津市优质农产品种植农场（北纬 $38^{\circ}34' \sim 40^{\circ}15'$ ，东经 $116^{\circ}43' \sim 118^{\circ}4'$ ），地处华

北平原东北部，属暖温带半湿润季风气候。该地区年平均气温为 14°C ，年降水量为 360~970 毫米，其中 75% 的降水集中在 6 月至 8 月。主要土壤类型包括潮土、褐土、沼泽土和滨海盐渍土（National Earth System Science Data Center, 2018）。该农场总面积约为 300 公顷，以水稻种植为主。本研究在农场内选取了“1-1”、“1-2”、“2-2”、“2-3”、“2-4”、“3-1”、“3-2”、“4-2”、“4-3”共 9 块水稻田作为试验区（图 1），总面积为 17 公顷，单个地块面积在 1.45~2.71 公顷之间。所种植的水稻品种为“津原 89-1”，于 2023 年 5 月 1 日移栽，2023 年 10 月 11 日收获。所有试验田块在水稻生长期间的关键田间管理措施（施肥、灌溉、病虫害防治等）均保持一致，遵循农场统一的标准化作业。




图1 研究区域及田块无人机RGB合成影像
Fig.1 Study area and RGB imagery of field by UAV

2.2 数据来源与预处理

2.2.1 无人机数据

本研究使用 DJI M3M 无人机（大疆，中国深圳）采集田间多光谱和 RGB 影像。该无人机搭载的成像系统包括一个 2000 万像素的 RGB 相机和一个多光谱相机，多光谱相机由四个 500 万像素传感器构成（焦距 25 毫米），可同步获取绿（Green, $560 \pm 5 \text{ nm}$ ）、红（Red, $650 \pm 5 \text{ nm}$ ）、红边（Red

Edge, $730 \pm 5 \text{ nm}$ ）和近红外（NIR, $860 \pm 5 \text{ nm}$ ）四个波段影像（图 2）。

无人机影像采集覆盖了水稻从生长初期至成熟的各关键生育期，以实现对其长势的动态监测。大多数试验田均按计划五个关键日期完成了数据获取，最终各田块获取的有效无人机影像为 3~5 景。部分田块由于客观原因未能在所有计划日期完成影像采集：其中，田块 4-3 因农事活动冲突缺少 6 月份的数据；田块 2-2 和 2-4 受天气影响仅在

8月至10月期间完成采样。所有飞行均在晴朗、风速低于3 m/s的条件下进行，飞行时间在当地10:00–14:00之间。飞行高度统一设置为30 m，影像的旁向和航向重叠度保持在70–80%。为保证数据质量，每次飞行前后均拍摄标准定标板，用于后续辐射校正。

原始无人机影像数据利用实景三维建模软件Agisoft Metashape Professional (v2.2.0, Agisoft, 俄罗斯) 进行处理，以生成高分辨率正射镶嵌图。处理流程包括：利用定标板进行辐射校正，将DN值转换为绝对反射率。随后，通过照片对齐匹配重叠影像中的连接点，以确定相机的相对位置。在此基础上，使用Metashape中的“高”质量模式进行多视角几何重建，生成密集点云，并在其基础上生成数字高程模型 (DEM) (Vishwakarma 等, 2025)。最后，将影像投影至DEM上，完成正射校正与镶嵌，生成具有精确地理坐标的正射影像。

本研究基于多光谱正射镶嵌影像的红光与近红外波段反射率计算NDVI (公式1) (Rouse Jr 等, 1973)。由于本研究的目标是生成田块尺度1米空间分辨率的NDVI图像，因此将所有NDVI影像使用最近邻插值法重采样至1米空间分辨率。

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (1)$$

其中 NIR 和 Red 分别对应传感器的近红外和红光波段。

2.2.2 Sentinel-2


Sentinel-2数据来自欧洲航天局 (ESA) 哥白尼计划，其重访周期为5天，可提供覆盖全球陆地表面的高时空分辨率多光谱影像 (Gascon, 2018; Martimort 等, 2007)。该卫星搭载的多光谱仪器 (MSI) 幅宽达290公里，可获取13个光谱波段数据，包括4个10 m分辨率波段、6个20 m分辨率波段和3个60 m分辨率波段 (详细波段范围见图2a)。

本研究使用经过大气校正和几何校正的Level-2A (L2A) 地表反射率产品 (Gascon 等, 2017; Drusch 等, 2012)，并筛选出2023年5月至10月期间研究区云量覆盖率低于10%的影像，各田块可用Sentinel-2影像数量均为14景 (日期分布见图2b)。为保留田块内部的空间细节，使用空间分辨

率为10 m的B4 (红光波段) 和B8 (近红外波段) 计算Sentinel-2 NDVI (公式1)。


2.2.3 PlanetScope

本研究采用了第三代PlanetScope SuperDove (以下简称SuperDove) 卫星星座。该数据提供8个光谱波段 (海岸蓝、蓝、绿I、绿II、黄、红、红边I和近红外)，空间分辨率为3米，其光谱特性与Sentinel-2非常相似 (图2a) (Roy 等, 2021)。本研究获取了2023年5月至10月期间研究区云量低于10%的SuperDove L3B地表反射率产品 (<https://www.planet.com/explorer>, 访问日期为2025年1月20日)，该产品已使用6S辐射传输模型 (Franke和Menz, 2007) 完成大气校正。各田块的具体影像获取日期见图2b。整个生长季内，获取的各个田块SuperDove影像数量在57–65景之间，为时空融合提供了高时间分辨率的观测数据。NDVI计算 (公式1) 使用该数据的红光与近红外波段。



(a) Sentinel-2、PlanetScope SuperDove与无人机传感器的波段分布，红色和橘色举行分别代表传感器的红波段和近红外波段

(a) Spectral band distribution of the Sentinel-2, PlanetScope SuperDove, and UAV sensors. Red and orange-colored boxes represent the red and NIR bands, respectively.



(b) 各田块Sentinel-2、PlanetScope SuperDove与无人机影像获取的时间序列

(b) Acquisition time series of Sentinel-2, PlanetScope SuperDove, and UAV imagery for each study field

图2 UAV、Sentinel-2和PlanetScope SuperDove的光谱波段与影像获取时间

Fig.2 Spectral bands and image acquisition dates from UAV , Sentinel-2 and PlanetScope SuperDove

3 研究方法

3.1 融合策略

本研究使用CACAO算法融合UAV NDVI、Sentinel-2 NDVI与SuperDove NDVI数据，并设计了两种数据组合策略，以评估高时间分辨率的SuperDove数据对生成每日1米NDVI影像精度的影响（图3）。

（1）策略1：Sentinel-2与无人机直接融合。该策略直接将高分辨率的UAV NDVI数据与10米的Sentinel-2 NDVI数据融合，以生成每日1米分辨率NDVI影像。

（2）策略2：Sentinel-2、SuperDove与无人机逐步融合。第一步，将Sentinel-2 NDVI与SuperDove NDVI融合，生成每日3米的NDVI图像。第二步，将UAV NDVI数据与上步生成的每日3米的NDVI影像融合，生成每日1米的NDVI影像。

3.2 时空融合算法

3.2.1 CACAO算法

CACAO（Consistent Adjustment of the Climatology to Actual Observations）算法是由Verger等（2013）提出的一种气候学曲线拟合的方法。该算法通过长时间序列的卫星数据构建一条平均

物候曲线，并调整时间平移（*shift*）和尺度缩放（*scale*）两个参数使其与特定年份的实际观测数据进行拟合，用于重建完整的逐日时间序列。本研究在原始方法基础上进行改进，将卫星 NDVI 时间

序列数据作为参考物候曲线，通过调整时间平移（*shift*）和尺度缩放（*scale*）两个参数对 UAV NDVI 数据进行拟合，最终生成 1 米分辨率的逐日 NDVI 影像。




图3 技术流程图

Fig.3 Technical workflow

采用最小二乘法进行参数优化，使卫星与 UAV NDVI 序列间的均方根误差（RMSE）（公式 3）最小化。在每次获取新的卫星影像时，模型参数会进行迭代更新，主要包括两个过程：

（1）前向预测（Forward prediction, FP）：基于当前最优参数，预测未来日期的 UAV NDVI；

（2）后向更新（Backward updating, BU）：当获取新的影像时，对参数进行重新优化，对历史时期的 UAV NDVI 重新估算。

$$UAV_{CACAO}^*(t) = scale \times S2(t + shift) \quad (2)$$

$$RMSE_{scale, shift} = \sqrt{\frac{1}{n} \sum_{i=1}^n (UAV(t_i) - UAV_{CACAO}^*(t_i))^2} \quad (3)$$

其中， UAV_{CACAO}^* 是使用 CACAO 算法进行前向预测或后向更新的 NDVI 值，*scale* 和 *shift* 分别是缩放因子和时间平移参数，通过最小二乘法确定。*scale* 和 *shift* 两个参数的搜索范围是基于前期试验中对水稻 NDVI 动态变化范围的初步分析确定的。具体设置如下：*shift* 的搜索范围为 -40 到 10 天（步长 0.5），*scale* 在 0.20 到 1.50 之间以 0.05 为增量进行优化。通过网格搜索迭代计算最优的 *shift* 和 *scale* 参数组合，可以生成每日 1 米分辨率的稻田 NDVI 影像。后续研究可通过系统的参数敏感性实验进一步优

化上述参数范围。CACAO 融合算法针对每个 1 米分辨率的无人机像元独立运行（图 4）。以 $t-1$ 开始的卫星观测时间为例，算法按照以下步骤进行像素级迭代计算：

（1）在时刻 $t+2$ ，当至少获取了两组无人机影像和两次卫星观测后，CACAO 算法开始计算。利用这些初始数据建立模型，计算前向预测的 NDVI 值（UAV-FP），并计算在时间 t 之前所有日期的后向更新 UAV NDVI（UAV-BU）（图 4a）。其中，初始化使用的两景无人机和卫星影像的采集时间无需完全对齐。

（2）在随后的每个卫星观测日期，进行 UAV-FP 预测，直到下一次无人机数据采集或生长季结束（图 4b）。

（3）当获取到第三景及后续的无人机图像时，利用累积的多景无人机数据重新优化模型参数进行 UAV-FP 预测，并更新从 $t-1$ 到 $t+4$ 期间所有先前日期的 UAV-BU 值（图 4c）。

（4）迭代重复步骤（2）和（3），直至最后一次无人机数据获取日期或生长季结束（图 4d）。

3.2.2 GLM-STF 算法




图4 对应于上述各个步骤的CACAO算法实现示意图

Fig.4 Schematic diagram of CACAO algorithm implementation corresponding to each step

GLM-STF是一种基于广义线性模型的时空融合算法，已成功应用于无人机与卫星影像的融合 (Ebrahimi 等, 2025)。该算法首先融合 MODIS 和 HLS (协调后的 Landsat 与 Sentinel-2) 数据，然后将得到的每日 HLS 数据与无人机影像融合，以生成每日高分辨率无人机影像。GLM-STF 算法的实现主要分为以下四个步骤：

(1) 数据预处理：为确保像素的精确对齐，所有低分辨率影像都使用最近邻插值算法重采样到与高分辨率图像相同的空间分辨率。在本研究中，将卫星影像（如 Sentinel-2 和 SuperDove）重采样到 1 米，保持与无人机影像的空间分辨率一致。

(2) 差异影像计算：对于两个参考日期 t_1 和 t_3 的图像对（包括低分辨率图像 C_1 、 C_3 和高分辨率图像 F_1 、 F_3 ），以及预测日期 t_2 的低分辨率图像 C_2 ，通过简单的相减计算四个差异图像： F_{13} （表示 t_3 时刻高分辨率影像的像素值减去 t_1 时刻高分辨率影像的像素值所得的变化量）， C_{13} （表示 t_3 时刻低分辨率影像的像素值减去 t_1 时刻低分辨率影像的像素值所得的变化量）， C_{12} （表示 t_2 时刻低分辨率影像的像素值减去 t_1 时刻低分辨率影像的像素值所得的变化量），以及 C_{23} （表示 t_3 时刻低分辨率影像的像素值减去 t_2 时刻低分辨率影像的像素值所得的变

化量）。

(3) GLM 模型训练与预测：利用 F_{13} 和 C_{13} 训练广义线性模型，以建立高分辨率影像变化和低分辨率影像变化之间的映射函数。在此过程中， F_{13} 作为因变量， C_{13} 作为自变量。将 C_{12} 图像输入到训练好的模型中，预测出 t_1 和 t_2 之间的高分辨率差异图像 (F_{12})。同样，将 C_{23} 影像输入到训练好的 GLM 中，可以预测出 F_{23} 影像 (t_2 和 t_3 之间的高分辨率差异影像)。

(4) 高分辨率图像合成：将步骤 (3) 中预测的高分辨率差异图像 (F_{12} 和 F_{13}) 与参考高分辨率图像 (F_1 和 F_3) 相结合，使用自适应局部加权方法合成预测日期 t_2 的最终高分辨率图像 (F_2)。此合成过程通过 Sigmoid 函数实现权重的分配，公式如下：

$$F_2 = W_1 \times (F_1 + F_{12}) + W_3 \times (F_3 + F_{23}) \quad (4)$$

其中参数 W_1 和 W_3 分别用于对从 F_1 和 F_3 获得的预测图像 F_2 进行加权，采用 Sigmoid 函数来计算 W_1 和 W_3 ，如下所示：

$$W_1 = \frac{1}{1 + e^{-k(|C_{23}| - |C_{12}|)}} \quad (5)$$

$$W_3 = 1 - W_1 \quad (6)$$

在本研究中，公式 (5) 中的参数 k 控制 Sigmoid 函数曲线的形状，其设置参考了 Ebrahimi

等（2025）的经验值。

GLM-STF算法的一个核心前提是需要每日的低分辨率影像来训练模型以预测每日的高分辨率影像。然而，Sentinel-2数据的重访周期为5到10天，且易受云层覆盖影响，无法满足算法需求。因此，本研究采用了一个两步策略来弥补这一差距：首先，将近每日的SuperDove NDVI与稀疏的Sentinel-2 NDVI进行融合，生成一个完整的每日10米NDVI数据集。随后，以该NDVI数据集作为低分辨率输入，与UAV NDVI融合生成每日1米分辨率NDVI数据集。

3.3 精度评估

3.3.1 不同平台NDVI的一致性

融合算法有效的前提是不同传感器对同一地物的观测具有一致性（Zhang, 2010）。然而，由于不同传感器光谱响应函数、几何校正模型和大气校正方法存在差异，这些可能直接影响NDVI的一致性和融合精度。因此，本研究首先进行了跨平台数据NDVI一致性评估。由于卫星和无人机图像的获取日期存在差异，为减小时间差异对一致性评估的影响，采用以下时间匹配策略：（1）SuperDove与Sentinel-2、UAV一致性分析：仅筛选获取日期完全一致的影像进行分析；（2）Sentinel-2与UAV一致性分析：考虑到UAV与Sentinel-2影像在整个水稻生长季的观测日期难以完全一致，若仅使用同日影像，可用数据数量将极为有限。为此，本研究采用在多源遥感数据一致性分析及时空融合领域中被广泛应用的 ± 3 天时间匹配窗口策略（Gao等, 2017; Emelyanova等, 2013），选取窗口内与UAV影像日期最接近的Sentinel-2影像进行匹配。同时，已有研究表明，收获前的水稻NDVI变化较为平缓（Tian等, 2024），因此使用 ± 3 天的时间窗口进行数据匹配是合理的。（3）在进行比较时，将较高分辨率的数据（如SuperDove 3米）重采样至较粗的分辨率（如Sentinel-2 10米）。

3.3.2 算法生成的每日NDVI图像的时空变化

本研究以田块“4-2”为例，分析了CACAO算法在两种数据组合策略下生成的每日1米NDVI时空变化。由于每次获得新的无人机NDVI图像时，后向更新的图像都会重新生成，因此每个日

期会进行更新。为简化分析，本研究仅展示和比较最终的更新结果，即在使用了所有可用的UAV NDVI图像后生成的每日1米NDVI图像。

3.3.3 评估指标

本研究使用留一法交叉验证CACAO算法生成的每日UAV NDVI与独立参考数据进行比较：

（1）留一法交叉验证（LOOCV）：针对每个无人机观测日期 t ，排除当天对应的无人机观测（ $UAV(t)$ ），利用剩余的无人机图像以及对应的Sentinel-2数据或Sentinel-2和SuperDove数据融合后的数据来预测日期 t 的无人机图像（ $UAV^*(t)$ ），并将此预测与实际观测进行比较。由于CACAO算法在获取新观测时会更新所有历史数据，更新后的UAV影像也将与实际观测值进行对比。此过程在整个生长季中对所有原始无人机影像上循环进行。如前所述，当所有来自Sentinel-2或Sentinel-2与SuperDove融合的结果都可用时，仅使用最终的后向更新无人机（UAV-BU）结果进行比较。根据Zhu等（2022）提出的综合评价框架，选取五个指标进行评估：皮尔逊相关系数（R）、均方根误差（RMSE）和平均差异（AD）用于衡量光谱精度，边缘特征差异（Edge）和局部二值模式（LBP）用于评价空间精度。AD为0时表示融合图像完美，其绝对值越大表示融合图像中的光谱偏差越大，负值和正值分别表示光谱信息的低估和高估。

$R(t) =$

$$\frac{\sum_{i=1}^N (UAV(t) - \mu_{UAV(t)}) (UAV^*(t) - \mu_{UAV^*(t)})}{\sqrt{\sum_{i=1}^N (UAV(t) - \mu_{UAV(t)})^2} \sqrt{\sum_{i=1}^N (UAV^*(t) - \mu_{UAV^*(t)})^2}} \quad (7)$$

$$RMSE(t) = \sqrt{\frac{1}{N} \sum_{i=1}^N (UAV(t) - UAV^*(t))^2} \quad (8)$$

$$AD(t) = \frac{1}{N} \sum_{i=1}^N (UAV^*(t) - UAV(t)) \quad (9)$$

其中， $UAV^*(t)$ 是在时间 t 前向预测或后向更新的无人机图像， $\mu_{UAV^*(t)}$ 是整个图像的均值， $\sigma_{UAV^*(t)}^2$ 是时刻前向预测或者后向更新的UAV图像的方差； $UAV(t)$ 是在同一日期 t 的无人机原始图像； $\mu_{UAV(t)}$ 是相同时刻 t 的整景UAV图像的其均值， $\sigma_{UAV(t)}^2$ 是时刻UAV图像的方差， $\sigma_{UAV^*(t)}^2$ 是在日期 t 无人机原始图像和预测图像之间的协方差； N 是每景图像中

的有效像元个数。

边缘特征差异 (Edge) 用于评估融合图像对空间边缘特征的保留能力。首先, 基于 Robert 交叉算子分别计算预测图像与参考图像中每个像素的边缘强度。对于图像中的像素 (i, j) , 其边缘特征值 $E_{i,j}$ 的计算公式如下:

$$E_{i,j} = |D_{ij} - D_{i+1,j+1}| + |D_{i,j+1} - D_{i+1,j}| \quad (10)$$

其中, D 代表图像元值。

在此基础上, 分别计算预测图像与参考图像中所有像元的 Robert 边缘特征均值 $E_{UAV^*(t)}$ 与 $E_{UAV(t)}$ 。为更准确地评估空间边缘的保持情况, 本研究仅对参考图像边缘特征值高于 90% 分位数的像元计算均值。

$$E_{UAV^*(t)} = \frac{1}{N} \sum_{i=1}^N E_{UAV^*(t),ij} \quad (11)$$

$$E_{UAV(t)} = \frac{1}{N} \sum_{i=1}^N E_{UAV(t),ij} \quad (12)$$

为使这些边缘特征具有可比性, 对预测图像和参考图像之间的每个空间特征的归一化 (公式 13), 其值为 0 时表示融合图像完美, 负值越大表示融合图像中的边缘特征过于平滑, 正值越大表示融合图像的边缘特征过于锐化。

$$Edge(t) = \frac{E_{UAV^*(t)} - E_{UAV(t)}}{E_{UAV^*(t)} + E_{UAV(t)}} \quad (13)$$

局部二值模式 (LBP) 用于量化图像局部纹理特征的保持能力。首先, 对图像中的每个像素, 以其 3×3 邻域内中心像素值为阈值, 对 8 个邻域像素进行二值化处理, 生成一个 8 位二进制数, 再将其转换为十进制数, 即得到该像素的 LBP 特征值。其计算公式如下:

$$L_{ij} = \sum_{p=0}^7 s(g_p - g_c) \cdot 2^p \quad (14)$$

$$g(x) = \begin{cases} 1 & x \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (15)$$

其中, g_c 是中心像素值, g_p 是第 p 个邻域像素值。

随后, 分别计算预测图像与参考图像中所有像元的 LBP 特征均值 $L_{UAV^*(t)}$ 与 $L_{UAV(t)}$, 并对其进行归一化 (公式 18), 其值为 0 时表示融合图像完美, 负值越大表示融合图像中的纹理特征过于平滑, 正值越大表示融合图像的纹理特征过于锐化。公式如下:

$$L_{UAV^*(t)} = \frac{1}{N} \sum_{i=1}^N L_{UAV^*(t),ij} \quad (16)$$

$$L_{UAV(t)} = \frac{1}{N} \sum_{i=1}^N L_{UAV(t),ij} \quad (17)$$

$$LBP(t) = \frac{L_{UAV^*(t)} - L_{UAV(t)}}{L_{UAV^*(t)} + L_{UAV(t)}} \quad (18)$$

(2) 与 GLM-STF 的比较: 近期 Ebrahimi 等 (2025) 针对无人机与卫星影像融合开发了 GLM-STF 算法, 具有较好的融合精度。该算法利用广义线性模型建立高、低分辨率影像间的映射关系, 可以较好地处理 UAV 与卫星数据之间较大的空间分辨率差异。因此选取该算法与 CACAO 算法进行对比, 以评估 CACAO 时空融合框架在处理跨平台、空间分辨率差异较大的数据的性能表现。

依据第 3.2.2 节详述的模型设置, 为田块 “4-2” 执行 GLM-STF 算法并生成预测影像。然后使用与上述相同的指标, 将得到的预测图像与原始 UAV NDVI 影像进行比较, 进而对两种算法的性能开展定量分析与讨论。

4 结果

4.1 不同平台 NDVI 的一致性

对 UAV、Sentinel-2 与 SuperDove NDVI 的一致性结果如图 5 所示。结果表明, SuperDove 和 Sentinel-2 的 NDVI 之间存在强相关性 ($R = 0.97$, $RMSE = 0.08$, 图 5a), 与 Ma 等 (2025) 的结论一致。相比之下, 卫星与无人机数据的一致性稍低。其中, Sentinel-2 与 UAV 在 ± 3 天匹配窗口下的相关性较好 ($R = 0.75$, $RMSE = 0.11$), 但略低于 SuperDove 与 UAV 之间的相关性 ($R = 0.80$, $RMSE = 0.13$), 这可能是因为不同传感器光谱响应函数及大气校正算法上存在差异。

从时间序列上看, 卫星与无人机 NDVI 均表现出水稻生长季典型的单峰物候曲线, 即 NDVI 在生长早期 (5—6 月) 逐渐增加, 在旺盛生长期 (7—8 月) 达到峰值, 在衰老期 (9—10 月) 逐渐下降 (图 6)。SuperDove 和 Sentinel-2 的 NDVI 时间序列曲线在整个生长季中均较为接近, 在各个物候期表现出良好的一致性。UAV NDVI 时间序列在趋势上与卫星数据保持一致, 但在部分日期存在一定偏差, 这可能与无人机影像对田块内部的局部异质性更为敏感、采集时的光照条件或大气校正差异有关。

从空间分布上看, 尽管三个平台数据空间分

分辨率差异明显,但其NDVI空间分布表现出一致的趋势(图7)。无人机影像空间分辨率最高,清晰地捕捉了田块内部的条带状种植模式和生长变化。SuperDove数据能够反映大致的空间差异,但是细

节有所损失,纹理更平滑。Sentinel-2空间分辨率最低,主要反映了整个田块的平均长势状况,可能无法完全捕捉精细的内部结构和生长变化。




图5 研究区内九个田块的 Sentinel-2、SuperDove 和 UAV NDVI 散点图

Fig.5 Scatter Plots of NDVI from Sentinel-2, SuperDove and UAV across nine fields.

图中颜色表示数据点密度,颜色越深代表该区域数据点越密集。




图6 研究区内各田块 Sentinel-2、SuperDove 和 UAV 的平均 NDVI 时间序列

Fig.6 Time series dynamics of average NDVI values of each field from Sentinel-2, SuperDove and UAV




图7 田块“4-2”的Sentinel-2、SuperDove和无人机NDVI空间分布及频率直方图

Fig.7 Spatial distribution of NDVI and corresponding frequency histograms for field ‘4-2’ derived from Sentinel-2, SuperDove and UAV platforms

4.2 CACAO融合结果的时空特征

4.2.1 时间序列变化

图8展示了田块“4-2”使用CACAO算法，在前向预测（FP）和后向更新（BU）模式下，以及两种数据组合策略（“UAV+Sentinel-2”和“SuperDove+Sentinel-2+UAV”）下生成的NDVI均值时间序列曲线。总体而言，两种数据策略组合方法和预测模式都有效地重建了水稻的物候动态。与前向预测模式相比，后向更新模式生成的NDVI时间序列更为平滑，尤其在生长旺季（DOY 150–250）期间的波动更小。这可能是因为后向更新模式使用了所有观测数据对参数进行优化。在前向预测模式下，使用SuperDove数据（“SuperDove+Sentinel-2+UAV”）的策略表现出更大的波动性。在后向更新模式下，不使用SuperDove的“UAV+Sentinel-2”的数据策略与原始UAV NDV的吻合度更高。这表明尽管SuperDove数据提高了时间分辨率，但是也可能引入额外的噪声或系统偏差，对融合的结果造成了扰动。

4.2.2 空间分布

从空间分布来看，与原始UAV NDVI图像相比，所有策略都表现出相似的空间分布，均可以较好地呈现水稻NDVI的整体空间分布（图9）。在生长旺季（如DOY 177），两种数据组合策略计算得到的NDVI图像差别较小。但是在生长后期（如DOY 256），“UAV+Sentinel-2”策略计算结果在空间分布上更接近原始UAV NDVI，这可能是因为SuperDove影像分辨率较高，但是其与UAV、Sentinel-2数据采集时间、传感器特性或数据处理过程中可能存在差异，引入了更多噪声。此外，后向更新模式计算结果在空间上呈现出更多低值区域，这是因为后向更新方法较前向预测方法填充了更多像素，其中包含了低值区域。

4.2.3 CACAO结果一致性分析

CACAO算法在所有数据组合策略和预测模式下生成的NDVI与原始UAV NDVI均具有强相关性（图10），相关性均超过了0.94，验证了融合结果的可靠性。大多数点聚集在1:1线附近，且这表

明预测结果与原始无人机 NDVI 之间存在强相关性, 融合效果较好。且前向预测模型的一致性略优于后向更新模式, 其散点更紧密地聚集在 1: 1 线周围, 特别是在 NDVI 高值区域 (0.6~0.9)。这可能是因为在 FP 模式是根据日期直接预测, 而 BU 使用了全部数据进行优化, 曲线更为平滑。此外,

在引入 SuperDove 数据的数据组合策略下的计算结果在散点图中呈现出轻微的“带状”分布。这可能表明高分辨率 SuperDove NDVI 的引入, 在融合过程中可能带来了更多的噪声或局部偏差, 从而对结果造成了细微影响。




图8 基于CACAO算法使用不同数据组合策略和预测模式得到的田块“4-2”的NDVI均值时间序列

Fig.8 The average NDVI time series of field '4-2' derived from CACAO algorithm using different data combination strategies and prediction modes




图9 在前向预测与后向更新两种预测模式下基于不同数据组合策略生成的田块“4-2”1米分辨率NDVI空间分布

Fig.9 Spatial distribution of 1m NDVI for field '4-2' generated by CACAO using different data combinations with forward prediction and backward update modes




图 10 基于 CACAO 算法不同数据组合策略和预测模式下的 NDVI 一致性散点图

Fig.10 Comparison of NDVI consistency scatter plots from CACAO algorithm using various data combination strategies and prediction modes

图中颜色表示数据点密度,颜色越深代表该区域数据点越密集。

4.3 精度评估

4.3.1 留一法交叉验证

本研究对 CACAO 使用“UAV+Sentinel-2”和“SuperDove+Sentinel-2+UAV”两种数据策略的前向预测结果进行了留一法交叉验证(图 11, 表 1)。两种策略生成的 NDVI 均与原始 UAV NDVI 具有相似的空间分布。在 DOY 222, 尽管“SuperDove+Sentinel-2+UAV”策略($R = 0.67$, $RMSE = 0.13$)在光谱相关性上优于“UAV+Sentinel-2”策略($R = 0.51$, $RMSE = 0.15$), 但两者的空间边缘均呈现轻微平滑, Edge 分别为 -0.07 和 -0.05 。同时两种数据组合策略的相关性均较小, 表明 CACAO 算法在 UAV 数据较少时预测早期 NDVI 影像的能力有

限。在 DOY 256 时, “UAV+Sentinel-2”策略表现出明显优势($R = 0.92$, $RMSE = 0.07$, $AD = 0.04$), 其空间结构与原始 UAV NDVI 图像保持高度一致($Edge = 0.01$, $LBP = -0.01$)。相比之下, “SuperDove+Sentinel-2+UAV”策略虽然 R 值接近 0.91, 但其光谱误差和偏差均显著增大($RMSE = 0.17$, $AD = 0.16$), 表明引入更多 SuperDove 数据并未在该时期提升光谱拟合的准确性。在生长后期, 两种数据组合策略不仅可以较好的拟合 NDVI, 也都保留了很好的空间细节(Edge 均为 -0.01 , LBP 均为 -0.01)。综合而言, 在整个生长季, 无人机与多种卫星遥感平台可以进行有效融合, 且精度较高, 可以满足实时监测的需求。

4.3.2 与 GLM-STF 算法对比




图 11 使用不同数据组合策略的留一法交叉验证结果的空间分布
Fig.11 Spatial distribution of leave-one-out cross validation results using different data combination strategies

表 1 使用不同数据组合的留一法交叉验证(LOOCV)结果
定量评估

Table 1 Quantitative evaluation results of LOOCV re-
sults using different data combinations

融合策略	DOY	R	RMSE	AD	Edge	LBP
UAV+Sentinel-2	222	0.51	0.15	0.05	-0.05	0.01
	256	0.92	0.07	0.04	0.01	-0.01
	282	0.88	0.1	0.07	-0.01	-0.01
SuperDove+ Sentinel-2+UAV	222	0.67	0.13	0.08	-0.07	0.01
	256	0.91	0.17	0.16	0.07	0.00
	282	0.89	0.09	0.06	-0.01	-0.01

注：表中加粗的精度值，表示在该日期下，通过对比两种数据组合策略所获得的最高精度。

为进一步验证CACAO算法的性能，本研究将其与GLM-STF算法进行了比较（图12）。结果显示，两种算法均取得了较高的预测精度（ $R > 0.8$ ）。生长初期，CACAO算法的综合性能显著优于GLM-STF。从光谱质量评价来看，CACAO的两种数据组合策略的预测结果均较佳， R 接近于1，RMSE和AD接近0，光谱误差明显低于GLM-STF算法，且GLM-STF存在明显的低估现象（ $AD = -0.24$ ）。同时，CACAO算法预测结果较好地保留了空间细节，其Edge接近于0，但GLM-STF的Edge为-0.25，说明该算法在早期存在较为严重的边缘平滑问题。进入生长中后期时（DOY 222及之后），GLM-STF算法的光谱精度明显提升，其 R 和RMSE值与CACAO非常接近。同时，其保持空间边缘特征能力也大幅提升并趋近于0。从整个生长季看，两种算法的LBP指标均接近于0，表明空间纹理保持能力均较好。综合来看，CACAO算法在生长季表现出更强的稳健性，其相关性始终高于0.92，RMSE、AD、Edge和LBP也具有较好的稳

定性，说明该算法在保证精度的同时，具有更可靠更稳定的时序重建能力。




图12 不同数据组合策略下使用CACAO与GLM_STF算法对田块“4-2”进行前向预测的精度评估指标时间序列
Fig.12 Temporal series of accuracy evaluation metrics for forward prediction on field ‘4-2’ by CACAO and GLM_STF algorithms under different data fusion strategies

5 讨论

5.1 跨平台数据一致性评估的有效性 with 局限性

结果表明, Sentinel-2、SuperDove 与 UAV 获取的水稻 NDVI 在时间序列与空间分布上均有良好的一致性, 其中 Sentinel-2 与 SuperDove 数据 NDVI 具有强相关性 ($R = 0.97$), 与 Ma 等 (2025) 对 Sentinel-2 与 SuperDove 数据一致性的研究结论相似。UAV 与卫星 NDVI 之间也呈现出较好的相关性 ($R > 0.75$), 这为后续多源遥感数据融合提供了重要的数据基础。在 UAV 与 Sentinel-2 数据一致性评估中, 本研究采用了 ± 3 天的时间匹配窗口以解决观测日期难以完全匹配的问题, 该策略在多源遥感时空融合与一致性分析中已被广泛采用 (Gao 等, 2017; Emelyanova 等, 2013)。尽管水稻 NDVI 在 3 天内变化较小, 但在生长迅速的阶段, 其生理状态仍可能出现比较明显的变化。此时 UAV 与 Sentinel-2 NDVI 差异不仅来源于传感器系统误差, 也可能包含了由水稻生长变化引起的差异。这种由影像日期不能完全匹配引入的误差, 在一定程度上可能会导致本研究对部分快速变化期的一致性结果的低估。

5.2 观测数据质量对时空融合算法精度的影响分析

遥感数据的观测质量是决定时空融合精度的关键因素之一。本研究中, Sentinel-2 NDVI 时间序列在 DOY 249 附近出现下降 (图 6), 主要源于当日影像受薄云污染, 而非水稻的真实物候变化。若采用传统线性插值或基于局部权重的融合方法中, 此类低质量观测数据易造成时序曲线的局部失真, 并进一步影响后续时期 (如 DOY 260–270) 作物长势的准确拟合。相比之下, 本研究采用的改进 CACAO 算法展现出良好的抗干扰能力。尽管在 DOY 249 因薄云污染出现了 NDVI 低值, 但融合后的 NDVI 曲线仍保持了符合水稻该物候阶段特征的高值平稳趋势 (图 8a)。这主要是因为 CACAO 算法可以基于生长季内所有可用观测数据, 通过对参考物候曲线进行整体缩放与平移, 有效降低低质量观测数据对融合结果的负面影响。这一优点对于多云雨地区的农田遥感监测尤为重要, 可在保证数据连续性的同时, 提高作物长势监测与决策支持的可靠性。

5.3 与传统时空融合算法的对比

STARFM (Gao 等, 2006)、ESTARFM (Zhu 等, 2010) 等传统的时空融合算法多基于空间权

重或像元解混的融合方法,并假设预测期间地物类型未发生显著变化。这些方法依赖成对的高低分辨率影像作为训练样本,通常通过一个固定的转化系数,将粗分辨率像元在预测时间内的变化量直接线性映射为细分辨率像元的变化量。然而,在作物快速生长的阶段,粗分辨率像元因混合效应所观测到的变化往往显著弱于细分辨率纯净像元的实际变化,这会导致对植被指数或者生物物理参数的高值区域出现系统性的低估,不能很好地适用于作物快速生长阶段(Tao等,2021)。本文所采用的改进CACAO算法,其核心思想与上述方法存在本质区别。该算法不依赖于同期的影像对,而是利用整个生长季的粗分辨率NDVI时间序列数据作为参考物候曲线,通过优化缩放与平移两个参数,使物候曲线在整体形态上与稀疏的高分辨率影像的观测值实现最佳拟合。因此CACAO算法可以更好地描述作物生长的非线性动态变化,有效地减少因混合像元问题引起的误差,从而在田块尺度作物生长连续监测中表现出更好的适应性与稳定性。在下一步研究中,计划将CACAO算法与STARFM、ESTARFM等经典时空融合方法进行系统性定量对比,进一步明确本方法在不同应用场景中的优势与局限。同时,也将深入探讨无人机、Sentinel-2与PlanetScope等不同平台间空间分辨率差异对融合精度的影响,为优化跨平台融合策略提供更为可靠的依据。

5.4 CACAO算法的局限性

尽管本研究改进的CACAO算法在生成水稻NDVI时间序列数据集上表现出较高的精度与鲁棒性,但仍存在一定的局限性。首先,算法的有效性基于一个关键假设:多源数据的NDVI时间序列具备相似的物候曲线形态。CACAO算法的核心是通过优化“缩放”(scale)与“平移”(shift)两个参数对参考物候曲线进行拟合。这一算法可以实施的前提是假设不同来源的NDVI时间序列具有较为相似的物候曲线形状。若因光谱响应、过境时间或大气校正等差异导致数据间存在明显的差异,则会影响参数的最优拟合,从而降低了融合精度。其次,当前“像元级”独立计算的策略在大范围应用时可能面临效率挑战。本研究对每个1米分辨率像元独立进行迭代参数优化,这使其应用于田块尺度上可以保证空间细节,但是若推广至更大

区域,其计算成本将会明显增加,可能成为制约实时业务化监测应用的因素。近期研究提出的基于贝叶斯动态线性模型与卡尔曼滤波的融合框架在实现数据融合时具有较高的计算效率(Li等,2026),在下一步研究中可尝试借鉴该方法的优化策略来提升CACAO算法在大范围应用时的运算效率。

5.5 时空融合框架的应用潜力

从方法原理上分析,本研究构建的基于CACAO的跨平台融合框架具备良好的普适性。算法的核心在于通过时间平移(shift)与尺度缩放(scale)对参考物候曲线进行拟合,因此对于其他同样具有物候规律的植被指数(如增强型植被指数、土壤调节植被指数)或关键生物物理参数(如叶面积指数、叶绿素含量),也可使用该时空融合框架为其生成高时空分辨率的时间序列数据集。因此,本研究提出的融合框架为生成田块尺度的多参数连续监测产品提供了可行的技术途径,未来可从2个角度进行拓展:首先,可拓展到更多的作物长势参数,如叶面积指数、叶绿素含量等进一步提高作物长势监测的精度和稳健性,以更全面地监测作物生长状况。其次,可将该方法应用于其他作物和研究区,以验证其普适性与可靠性。

6 结论

本研究通过协同利用无人机、Sentinel-2及SuperDove遥感影像,成功构建并验证了一套能够生成每日1米空间分辨率水稻NDVI时间序列的时空融合框架。主要结论如下:

(1) 无人机、Sentinel-2和SuperDove平台的NDVI数据在时间序列和空间分布上均表现出良好的一致性,其中Sentinel-2与SuperDove的相关性达0.97,无人机与卫星数据的相关性超过0.75,为跨平台数据融合提供了可靠基础。

(2) CACAO算法能够有效重建水稻的完整物候曲线,无论是采用“UAV+Sentinel-2”还是“SuperDove+Sentinel-2+UAV”策略,其融合结果均与UAV NDVI高度相关($R > 0.94$)。其中,后向更新模式因使用了生长季的全部数据,生成的NDVI时间序列更平滑、更稳定。前向预测模式则适用于近实时监测,虽生成的NDVI时间序列波动

性较大,但在部分日期更接近原始UAV NDVI。

(3) 在关键生长期,将SuperDove数据加入到预测模型中,可以在一定程度上提高融合精度,这表明加入时间密集的卫星影像可以在作物长势监测时发挥一定作用。然而引入更多的数据源也可能带来更多的噪声导致融合精度下降。

(4) 与GLM-STF算法相比,CACAO算法在整个生长季表现出更优的稳定性与精度,尤其在观测数据较少的生长初期,基于物候曲线的拟合方式更为稳健。

综上,本研究提出的“无人机-卫星光学遥感”跨平台时空融合框架,有效克服了单一遥感平台的局限性,为实现田块尺度的作物长势精准、连续监测提供了有效的解决方案,在智慧农业与精准管理中具有较好的应用前景。

参考文献(References)

- Beerli O and Peled A. 2009. Geographical model for precise agriculture monitoring with real-time remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64 (1):47-54 [DOI: 10.1016/j.isprsjprs.2008.07.007].
- Bouyet A and Le Toan T. 2011. Use of ENVISAT/ASAR wide-swath data for timely rice fields mapping in the Mekong River Delta. *Remote Sensing of Environment*, 115 (4): 1090-101 [DOI: 10.1016/j.rse.2010.12.014].
- Claverie M, Ju J C, Masek J G, Dungan J L, Vermote E F, Roger J-C, Skakun S V and Justice C. 2018. The Harmonized Landsat and Sentinel-2 surface reflectance data set. *Remote Sensing of Environment*, 219:145-61 [DOI: 10.1016/j.rse.2018.09.002].
- Dong J W, Xiao X M, Menarguez M A, Zhang G L, Qin Y W, Thau D, Biradar C and Moore III B. 2016. Mapping paddy rice planting area in northeastern Asia with Landsat 8 images, phenology-based algorithm and Google Earth Engine. *Remote Sensing of Environment*, 185:142-54 [DOI: 10.1016/j.rse.2016.02.016].
- Drusch M, Del Bello U, Carlier S, Colin O, Fernandez V, Gascon F, Hoersch B, Isola C, Laberini P, Martimort P, Meygret A, Spoto F, Sy O, Marchese F and Bargellini P. 2012. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120: 25-36 [DOI: 10.1016/j.rse.2011.11.026].
- Ebrahimi H, Yu T and Zhang Z. 2025. Developing a spatiotemporal fusion framework for generating daily UAV images in agricultural areas using publicly available satellite data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 220:413-27 [DOI: 10.1016/j.isprsjprs.2024.12.024].
- Emelyanova I V, McVicar T R, Van Niel T G, Li L T and van Dijk A I J M. 2013. Assessing the accuracy of blending Landsat - MODIS

surface reflectances in two landscapes with contrasting spatial and temporal dynamics: A framework for algorithm selection. *Remote Sensing of Environment*, 133:193-209 [DOI: 10.1016/j.rse.2013.02.007].

- Franke J and Menz G. 2007. Multi-temporal wheat disease detection by multi-spectral remote sensing. *Precision Agriculture*, 8 (3):161-72 [DOI: 10.1007/s11119-007-9036-y].
- Gao F, Anderson M, Daughtry C, Karnieli A, Hively D and Kustas W. 2020. A within-season approach for detecting early growth stages in corn and soybean using high temporal and spatial resolution imagery. *Remote Sensing of Environment*, 242 [DOI: 10.1016/j.rse.2020.111752].
- Gao F, Anderson M C, Zhang X Y, Yang Z W, Alfieri J G, Kustas W P, Mueller R, Johnson D M and Prueger J H. 2017. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. *Remote Sensing of Environment*, 188:9-25 [DOI: 10.1016/j.rse.2016.11.004].
- Gao F, Masek J, Schwaller M and Hall F. 2006. On the blending of the Landsat and MODIS surface reflectance: Predicting daily Landsat surface reflectance. *IEEE Transactions on Geoscience and Remote Sensing*, 44 (8): 2207-18 [DOI: 10.1109/TGRS.2006.872081].
- Gascon F. 2018. Sentinel-2 for agricultural monitoring. *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*. Valencia: IEEE: 8166-8168 [DOI: 10.1109/IGARSS.2018.8517942].
- Gascon F, Bouzinac C, Thépaut O, Jung M, Francesconi B, Louis J, Lonjou V, Lafrance B, Massera S, Gaudel-Vacaresse A, Languille F, Alhammoud B, Viallefont F, Pflug B, Bieniarz J, Clerc S, Pessiot L, Trémas T, Cadau E, De Bonis R, Isola C, Martimort P and Fernandez V. 2017. Copernicus Sentinel-2A Calibration and Products Validation Status. *Remote Sensing*, 9 (6) [DOI: 10.3390/rs9060584].
- Gevaert C M, Suomalainen J, Tang J and Kooistra L. 2015. Generation of Spectral - Temporal Response Surfaces by Combining Multi-spectral Satellite and Hyperspectral UAV Imagery for Precision Agriculture Applications. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8 (6): 3140-6 [DOI: 10.1109/jstars.2015.2406339].
- Hilker T, Wulder M A, Coops N C, Seitz N, White J C, Gao F, Masek J G and Stenhouse G. 2009. Generation of dense time series synthetic Landsat data through data blending with MODIS using a spatial and temporal adaptive reflectance fusion model. *Remote Sensing of Environment*, 113 (9): 1988-99 [DOI: 10.1016/j.rse.2009.05.011].
- Jiang X, Fang S H, Huang X, Liu Y H and Guo L L. 2021. Rice mapping and growth monitoring based on time series GF-6 images and red-edge bands. *Remote Sensing*, 13 (4): 579 [DOI: 10.3390/rs13040579].
- Jin X, Tang P and Zhang Z. 2021. Sequence image datasets construction via deep convolution networks. *Remote Sensing*, 13 (9):1853 [DOI: 10.3390/rs13091853].

- Kukunuri A N J and Singh D. 2022. Efficient Application of Drone with Satellite data for Early-Stage Wheat Detection: For Precision Agriculture Monitoring. IGARSS 2022, 2022 IEEE International Geoscience and Remote Sensing Symposium. Kuala Lumpur: IEEE: 4388-4391 [DOI: 10.1109/IGARSS46834.2022.9883266]
- Li W J, Weiss M, Buis S, Verger A, Jay S, Ren Z H, Wu W B, Jiang J, Comar A and De Solan B. 2026. NRT-GSF: A novel near-real-time ground-satellite fusion algorithm to retrieve daily green area index at field scale. *Remote Sensing of Environment*, 333 [DOI: 10.1016/j.rse.2025.115160].
- Lin W P, Li H M, Ni J, Jiang X P and Zhu Y. 2020. Monitoring rice growth based on a portable three-band instrument for crop growth monitoring and diagnosis. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 36(20): 203-208 (林维潘, 李怀民, 倪军, 蒋小平, 朱艳. 2020. 基于便携式三波段作物生长监测仪的水稻长势监测. *农业工程学报*, 36(20):203-8 [DOI: 10.11975/j.issn.1002-6819.2020.20.024])
- Liu J B, Ma Y, Wu Y T and Chen F. 2016. Review of methods and applications of high spatiotemporal fusion of remote sensing data. *Journal of Remote Sensing*, 20(5): 1038 - 1049 (刘建波, 马勇, 武易天, 陈甫. 2016. 遥感高时空融合方法的研究进展及应用现状. *遥感学报*, 20(05):1038-49 [DOI: 10.11834/jrs.20166218])
- Liu S J, Liu J, Tan X Y, Chen X H and Chen J. 2024. A Hybrid Spatio-temporal Fusion Method for High Spatial Resolution Imagery: Fusion of Gaofen-1 and Sentinel-2 over Agricultural Landscapes. *Journal of Remote Sensing*, 4: 0159 [DOI: 10.34133/remotesensing.0159]
- Liu W J, Zeng Y N and Zhang M. 2018. Mapping rice paddy distribution by using time series HJ blend data and phenological parameters. *Journal of Remote Sensing*, 22(3): 381 - 391 (柳文杰, 曾永年, 张猛. 2018. 融合时间序列环境卫星数据与物候特征的水稻种植区提取. *遥感学报*, 22(03):381-91 [DOI: 10.11834/jrs.20187298])
- Lou Y F, Huang K, Yang G, Sun W W, Shao C C, Liu W W, Wang L H and Hu J. 2025. A rice distribution extraction method based on Sentinel-2 time-series data. *National Remote Sensing Bulletin*, 29(5): 1260-1272 (娄铁峰, 黄可, 杨刚, 孙伟伟, 邵春晨, 刘围围, 王利花, 胡静. 2025. 基于 Sentinel-2 时间序列数据的水稻分布提取方法. *遥感学报*, 29(05): 1260-72 [DOI: 10.11834/jrs.20254113])
- Ma Y M, Li W J, Wang L W, Liu S Y, Dong M X and Shi Z C. 2025. Evaluating the consistency between Sentinel-2 and Planet constellation at field scale: illustration over winter wheat. *Precision Agriculture*, 26(2) [DOI: 10.1007/s11119-025-10226-4]
- Martimort P, Arino O, Berger M, Biasutti R, Carnicero B, Del Bello U, Fernandez V, Gascon F, Greco B and Silvestrin P. 2007. Sentinel-2 optical high resolution mission for GMES operational services. 2007 IEEE International Geoscience and Remote Sensing Symposium. Barcelona: IEEE: 2677-2680 [DOI: 10.1109/IGARSS.2007.4423394]
- Seo B, Lee J, Lee K-D, Hong S and Kang S. 2019. Improving remotely-sensed crop monitoring by NDVI-based crop phenology estimators for corn and soybeans in Iowa and Illinois, USA. *Field Crops Research*, 238:113-28 [DOI: 10.1016/j.fcr.2019.03.015].
- Soil SubCenter, National Earth System Science Data Center, National Science & Technology Infrastructure of China (<http://soil.geodata.cn>)
- Sun L, Gao F, Anderson M, Kustas W, Alsina M, Sanchez L, Sams B, McKee L, Dulaney W, White W, Alfieri J, Prueger J, Melton F and Post K. 2017. Daily Mapping of 30 m LAI and NDVI for Grape Yield Prediction in California Vineyards. *Remote Sensing*, 9(4) [DOI: 10.3390/rs9040317].
- Pajares G. 2015. Overview and current status of remote sensing applications based on unmanned aerial vehicles (UAVs). *Photogrammetric Engineering & Remote Sensing*, 81(4):281-330 [DOI: 10.14358/PERS.81.4.281]
- Rouse Jr J W, Haas R H, Schell J and Deering D 1973. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation.
- Roy D P, Huang H, Houborg R and Martins V S. 2021. A global analysis of the temporal availability of PlanetScope high spatial resolution multi-spectral imagery. *Remote Sensing of Environment*, 264: 112586 [DOI: 10.1016/j.rse.2021.112586].
- Song J, Zhang Z and Han J C. 2024. Accurately retrieving vegetation phenology at high spatial and temporal resolutions based on GEE and multi-source remote sensing data fusion. *National Remote Sensing Bulletin*, 28(11): 2910-2926 (宋杰, 张朝, 韩继冲. 2024. 基于 GEE 与多源遥感数据融合反演高时空分辨率物候. *遥感学报*, 28(11):2910-26 [DOI: 10.11834/jrs.20232646])
- Sporchia F, Antonelli M, Aguilar-Martínez A, Bach-Faig A, Caro D, Davis K F, Sonnino R and Galli A. 2024. Zero hunger: future challenges and the way forward towards the achievement of sustainable development goal 2. *Sustainable Earth Reviews*, 7(1): 10 [DOI: 10.1186/s42055-024-00078-7]
- Sun L, Gao F, Xie D H, Anderson M, Chen R Q, Yang Y, Yang Y and Chen Z X. 2021. Reconstructing daily 30 m NDVI over complex agricultural landscapes using a crop reference curve approach. *Remote Sensing of Environment*, 253: 112156 [DOI: 10.1016/j.rse.2020.112156].
- Tao G F, Jia K, Wei X Q, Xia M, Wang B, Xie X D, Jiang B, Yao Y J and Zhang X T. 2021. Improving the spatiotemporal fusion accuracy of fractional vegetation cover in agricultural regions by combining vegetation growth models. *International Journal of Applied Earth Observation and Geoinformation*, 101 [DOI: 10.1016/j.jag.2021.102362].
- Tian J L, Tian Y Z, Wan Y M, Yuan C X, Liu K N and Wang Y. 2024. Research on the Temporal and Spatial Changes and Driving Forces of Rice Fields Based on the NDVI Difference Method. *Agriculture*, 14(7) [DOI: 10.3390/agriculture14071165].
- Tucker C J, Pinzon J E, Brown M E, Slayback D A, Pak E W, Mahoney R, Vermote E F and El Saleous N. 2005. An extended AVHRR 8-km NDVI dataset compatible with MODIS and SPOT vegetation NDVI data. *International Journal of Remote Sensing*, 26(20):4485-98].

- Unicef. 2024. The state of food security and nutrition in the world 2024. [DOI: 10.4060/cd1254en]
- Verger A, Baret F, Weiss M, Kandasamy S and Vermote E. 2013. The CACAO Method for Smoothing, Gap Filling, and Characterizing Seasonal Anomalies in Satellite Time Series. *IEEE Transactions on Geoscience and Remote Sensing*, 51 (4): 1963-72 [DOI: 10.1109/tgrs.2012.2228653]
- Vishwakarma S K, Bhattarai B, Kothari K and Pandey A. 2025. Inter-comparison of machine learning models for estimating leaf area index of rice using UAV-based multispectral imagery. *Physics and Chemistry of the Earth, Parts A/B/C*, 103977 [DOI: 10.1016/j.pce.2025.103977].
- Wang J, Wu Z W, Jiang H, Ke J and Prodhon F A. 2025. Rice yield prediction of unmanned farm based on random forest and remote sensing vegetation index. *Journal of Intelligent Agricultural Mechanization*, 6(2): 97-104 (王俊, 吴振伟, 姜海, 柯娟, Prodhon F A. 2025. 基于随机森林及遥感植被指数的无人农场水稻产量预测研究. *智能化农业装备学报(中英文)*, 6 (02):97-104 [DOI: 10.12398/j.issn.2096-7217.2025.02.009])
- Wang W K, Zhang J Y, Wang H, Cao Q, Tian Y C, Zhu Y, Cao W X and Liu X J. 2023. Non-Destructive Monitoring of Rice Growth Key Indicators Based on Fixed-wing UAV Multispectral Images. *Scientia Agricultura Sinica*, 56(21):4175-4191 (王伟康, 张嘉懿, 汪慧, 曹强, 田永超, 朱艳, 曹卫星, 刘小军. 2023. 基于固定翼无人机多光谱影像的水稻长势关键指标无损监测. *中国农业科学*, 56 (21): 4175-91 [DOI: 10.3864/j.issn.0578-1752.2023.21.004])
- Wang Y W, Ma X, Tan S Y, Jia X N, Chen J Y, Qin Y J, Hu X H and Zheng H W. 2024. Inverting rice nitrogen content with multimodal data fusion of unmanned aerial vehicle remote sensing and ground observations. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 40(18): 100-109 (王宇唯, 马旭, 谭德妍, 贾兴娜, 陈嘉盈, 秦亦娟, 胡希红, 郑惠文. 2024. 无人机遥感与地面观测的多模态数据融合反演水稻氮含量. *农业工程学报*, 40 (18):100-9 [DOI: 10.11975/j.issn.1002-6819.202404175])
- Weng Q H, Fu P and Gao F. 2014. Generating daily land surface temperature at Landsat resolution by fusing Landsat and MODIS data. *Remote Sensing of Environment*, 145:55-67 [DOI: 10.1016/j.rse.2014.02.003]
- Xu Z H, Sun H, Zhang T, Xu H Y, Wu D and Gao J H. 2024. The high spatial resolution Drought Response Index (HiDRI): An integrated framework for monitoring vegetation drought with remote sensing, deep learning, and spatiotemporal fusion. *Remote Sensing of Environment*, 312: 114324 [DOI: 10.1016/j.rse.2024.114324].
- Yang J M, Wu Y, Wei Y X, Wang B, Ru C, Ma Y Y and Zhang Y. 2019. A model for the fusion of multi-source data to generate high temporal and spatial resolution VI data. *Journal of Remote Sensing*, 23(5): 935 - 943 (杨军明, 吴昱, 魏永霞, 王斌, 汝晨, 马瑛瑛, 张奕. 2019. 多源数据融合的高时空分辨率植被指数生成. *遥感学报*, 23 (05):935-43 [DOI:10.11834/jrs.20198204])
- Yuan L, Yu Q M, Xiang L R, Zeng F G, Dong J, Xu Q G and Zhang J C. 2025. Integrating UAV and high-resolution satellite remote sensing for multi-scale rice disease monitoring. *Computers and Electronics in Agriculture*, 234: 110287 [DOI: 10.1016/j.compag.2025.110287].
- Zeng Y L, Hao D L, Huete A, Dechant B, Berry J, Chen J M, Joiner J, Frankenberg C, Bond-Lamberty B, Ryu Y, Xiao J F, Asrar G R and Chen M. 2022. Optical vegetation indices for monitoring terrestrial ecosystems globally. *Nature Reviews Earth & Environment*, 3 (7):477-93 [DOI: 10.1038/s43017-022-00298-5].
- Zhang J X. 2010. Multi-source remote sensing data fusion: status and trends. *International journal of image and data fusion*, 1 (1):5-24 [DOI: 10.1080/19479830903561035]
- Zhang X Y, Friedl M A, Schaaf C B, Strahler A H, Hodges J C, Gao F, Reed B C and Huete A. 2003. Monitoring vegetation phenology using MODIS. *Remote Sensing of Environment*, 84 (3):471-5].
- Zhang X Y, Gao F, Wang J M and Ye Y C. 2021. Evaluating a spatiotemporal shape-matching model for the generation of synthetic high spatiotemporal resolution time series of multiple satellite data. *International Journal of Applied Earth Observation and Geoinformation*, 104: 102545 [DOI: 10.1016/j.jag.2021.102545].
- Zhao B T, Hua C H, Ye C Y, Xiong Y C, Qian T, Cheng T, Yao X, Zheng H B, Zhu Y, Cao W X and Jiang C Y. 2025. Research Progress on Remote Sensing Monitoring and Intelligent Decision-Making Algorithms for Rice Production. *Smart Agriculture*, 7(2): 57-72 (赵柄婷, 华传海, 叶晨洋, 熊育春, 钱涛, 程涛, 姚霞, 郑恒彪, 朱艳, 曹卫星, 江冲亚. 2025. 水稻生产遥感监测与智慧决策研究进展. *智慧农业(中英文)*, 7 (02):57-72 [DOI: 10.12133/j.smartag.SA202501002])
- Zhao W Z, Qu Y, Chen J G and Yuan Z L. 2020. Deeply synergistic optical and SAR time series for crop dynamic monitoring. *Remote Sensing of Environment*, 247: 111952 [DOI: 10.1016/j.rse.2020.111952].
- Zhu X L, Cai F Y, Tian J Q and Williams T K-A. 2018. Spatiotemporal fusion of multisource remote sensing data: Literature survey, taxonomy, principles, applications, and future directions. *Remote Sensing*, 10 (4):527 [DOI: 10.3390/rs10040527]
- Zhu X L, Chen J, Gao F, Chen X H and Masek J G. 2010. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. *Remote Sensing of Environment*, 114 (11):2610-23 [DOI: 10.1016/j.rse.2010.05.032]
- Zhu X L, Zhan W F, Zhou J X, Chen X H, Liang Z C, Xu S and Chen J. 2022. A novel framework to assess all-round performances of spatiotemporal fusion models. *Remote Sensing of Environment*, 274: 113002 [DOI: 10.1016/j.rse.2022.113002].

Synergistic use of satellite and UAV imagery for continuous monitoring of

field-scale paddy rice NDVI

REN Zihan¹, XU Jiaqi¹, WEI Shanshan², WU Wenbin¹, LI Wenjuan¹

1.State Key Laboratory of Efficient Utilization of Arable Land in China, Institute of Agricultural Resources and Regional Planning,
Chinese Academy of Agricultural Sciences, Beijing 100081, China;

2.Centre for Remote Imaging, Sensing and Processing, National University of Singapore, Singapore 119076, Singapore

Abstract: Objective The real-time and precise monitoring of crop growth status at the field scale is a critical component for achieving modern precision agriculture. Multi-source remote sensing technologies, including satellite platforms and unmanned aerial vehicles (UAVs), have emerged as effective non-destructive tools for this purpose. However, these data sources present a significant spatiotemporal trade-off, limiting their independent utility. Satellite remote sensing, while offering broad-area coverage, is often constrained by adverse weather conditions and insufficient spatial resolution to capture in-field variability. Conversely, UAV remote sensing provides exceptionally high spatial resolution but is hampered by limited battery endurance, making large-scale continuous (e.g., daily) monitoring challenging. Consequently, a single data source is inadequate for supporting the continuous monitoring of crop growth at the field scale. To address this critical gap, this study proposes a cross-platform spatiotemporal fusion method. The objective is to synergistically integrate satellite and UAV data, effectively leveraging their complementary temporal and spatial resolutions to generate a continuous, high-resolution dataset for precision agriculture. Method This research was based on a synergistic combination of multi-platform, multispectral remote sensing data, including high-resolution UAV imagery, Sentinel-2 data and PlanetScope SuperDove data. We developed an improved CACAO (Consistent Adjustment of the Climatology to Actual Observations) algorithm, adapting its core logic for cross-platform data fusion rather than its original climatological application. Two distinct data combination strategies were designed and tested: (1) a baseline “UAV+Sentinel-2” strategy and (2) an enhanced “SuperDove+Sentinel-2+UAV” strategy, which integrates high-frequency commercial satellite data. The CACAO framework was implemented using two distinct modes: a “forward prediction” (FP) mode, designed for near real-time applications, and a “backward updating” (BU) mode, which iteratively refines historical estimates as new data becomes available. The final output of the framework is a near real-time, daily 1-meter resolution normalized difference vegetation index (NDVI) time-series dataset. The accuracy of the fusion results was rigorously evaluated using two methods: (1) Leave-One-Out Cross-Validation (LOOCV), which assesses the model’s predictive power, and (2) a benchmark comparison against the established GLM-STF (Generalized Linear Model-based Spatiotemporal Fusion) algorithm. Result The prerequisite for data fusion was confirmed as NDVI data from the different platforms exhibited good consistency, with a strong correlation between Sentinel-2 and SuperDove ($R = 0.97$) and a reliable correlation was observed between UAV and satellite data ($R > 0.75$). In addition, the CACAO algorithm was proven to effectively reconstruct the phenological dynamics of the rice crop. A key finding was that the backward updating (BU) mode produced a significantly smoother and more robust NDVI time series than the forward prediction (FP) mode. Both CACAO-based data combination strategies achieved high overall accuracy ($R > 0.94$). Critically, the study demonstrated that introducing high-temporal-resolution SuperDove data during key phenological stages can substantially improve accuracy, with the correlation increasing from 0.51 to 0.67 in a specific validation case. Finally, in the comparative analysis, the CACAO algorithm demonstrated greater stability and slightly higher accuracy than the GLM-STF algorithm, particularly showing more robust performance across the entire growing season. Conclusion In conclusion, the cross-platform fusion framework proposed in this study, centered on the improved CACAO algorithm, is an effective and robust solution for generating continuous, high-precision (daily 1-meter) field-scale rice NDVI time series. This approach successfully overcomes the limitations of single-source data platforms. The framework provides strong technical support for the fine-grained monitoring of crop growth and the implementation of precision management strategies in modern agriculture.

Key words: PlanetScope, Sentinel-2, spatiotemporal data fusion, growth monitor, precision agriculture, field scale, phenological curve, near real-time monitoring

Supported by Supported by National Natural Science Foundation of China (No. 2023YFD2300500)