

耦合红边波段特征的农作物叶面积指数反演

徐保东¹, 宋祝蓓佳¹, 吴同舟¹, 孟可¹, 王琦¹, 魏浩东², 尹高飞³

1. 华中农业大学 资源与环境学院 数字农业研究院, 武汉 430070;

2. 华中农业大学 植物科学技术学院, 武汉 430070;

3. 西南交通大学 地球科学与工程学院, 成都 610031

摘要: 叶面积指数 LAI (Leaf Area Index) 是表征作物冠层结构与长势的关键参数, 利用遥感技术对其进行准确及时的监测对于田间水肥管理、粮食安全保障以及农业生产潜力评估等具有重要意义。红边作为指示叶片生理及冠层结构变化的敏感性光谱波段, 已被多种中高分辨率 (10—30 m) 卫星传感器配置并广泛应用于作物参数反演, 为进一步提升作物 LAI 反演精度提供了新的契机。然而, 现有研究在红边波段应用于 LAI 反演的方式上存在较大差异, 且由于研究区域的不同, 如何有效利用红边波段提升 LAI 反演精度仍未明确。基于此, 本研究以 PROSAIL 模型和机器学习算法结合的混合法为反演策略, 利用包含 3 个红边波段的 Sentinel-2 影像和国家生态系统观测研究网络提供的全国主粮作物 (水稻、小麦和玉米) 地面 LAI 实测数据, 通过优选机器学习模型及波段组合, 构建了耦合红边波段特征的农作物 LAI 反演算法, 并在不同场景下开展了系统评估。结果表明, 多层感知机 (MLPR) 拟合 LAI 与多波段反射率的效果最佳, 且红边波段的引入可有效提升 LAI 反演精度, 其中联合引入红边 1 (RE1) 和红边 3 (RE3) 的反演效果最优 ($R^2=0.784$, $RMSE=0.826$), 与不加入红边波段的 ZI 组合 (Green+Red+NIR+SWIR1+SWIR2) 相比, R^2 提升了 4.9%, $RMSE$ 降低了 15.6%。同时, 引入红边波段不仅可减少 LAI 反演的系统性偏差, 而且在 LAI 中高值区间 ($4<LAI<5$) 有效地缓解了饱和效应的影响 ($|Bias|$ 和 $RMSE$ 分别下降了 52.2% 和 41.4%)。此外, 不同作物对红边信息的响应存在差异, 引入 RE1 和 RE3 后, 玉米 LAI 反演精度提升最为显著 (R^2 提升 17.9%, $RMSE$ 降低 29.1%)。本研究通过耦合红边波段所构建的反演算法, 可显著提升不同作物类型 LAI 反演精度, 为大尺度、长时序农作物长势精准监测提供了重要技术支撑。

关键词: 农作物叶面积指数, 红边波段, PROSAIL 模型, 机器学习, 波段优选

中图分类号: P2

引用格式: 徐保东, 宋祝蓓佳, 吴同舟, 孟可, 王琦, 魏浩东, 尹高飞. 2026. 耦合红边波段特征的农作物叶面积指数反演. 遥感学报, 30(5): 1374–1391

Xu B D, Song Z B J, Wu T Z, Meng K, Wang Q, Wei H D and Yin G F. 2026. Retrieval of crop leaf area index by coupling red-edge band features. National Remote Sensing Bulletin, 30(5): 1374–1391 [DOI: 10.11834/jrs.20265383]

1 引言

作物长势监测在田间水肥管理、粮食安全保障以及农业生产潜力评估等方面发挥着至关重要的作用 (Djamai 等, 2025; Zérah 等, 2024)。叶面积指数 LAI (Leaf Area Index) 定义为单位地表面上绿叶表面积总和的一半, 是表征植被冠层结构与功能的重要生物物理参数 (Chen 和 Black, 1992)。作为作物生长和发育状态的核心指标, LAI 不仅直接决定了冠层对光合有效辐射的截获能力, 而且深刻影响了作物的光合作用、蒸散作用以及

陆表能量与物质循环等过程 (Chen 等, 2019)。卫星遥感技术为获取大面积、长时序 LAI 数据提供了有效手段。当前, 已有多套全球长时序 LAI 产品发布, 如 MODIS、GLASS、GEOV3 和 MuSyQ 等 (Fang 等, 2019a; Fernandes 等, 2023; 梁顺林等, 2023)。然而, 由于这些产品多依赖中低空间分辨率 (>100 m) 遥感数据, 受农业景观异质性和混合像元效应的影响, 其在作物长势监测中的精度存在较大不确定性 (Fang 等, 2019b; Myneni 等, 2002)。因此, 亟需依托中高空间分辨率 (10—30 m) 遥感影像, 在更精细的尺度上开展作

收稿日期: 2025-09-15; 预印本: 2026-01-25

基金项目: 国家自然科学基金 (编号: 42271360, 42001303)

第一作者简介: 徐保东, 研究方向为农业遥感。E-mail: xubaodong@mail.hzau.edu.cn

物 LAI 高精度监测。

基于中高分辨率遥感影像的 LAI 反演方法主要包括 3 类: 经验关系法、物理模型法和混合法 (贺敏等, 2022; Verrelst 等, 2015)。经验关系法通过建立实测 LAI 与遥感观测量 (反射率、植被指数等) 的统计关系并推广至区域尺度, 方法简便、计算效率高, 但因地表条件和大气环境的差异, 导致其在跨区域、跨时相应用中泛化能力不足 (Li 等, 2023; 唐以洁和王群明, 2025; 王宁等, 2024)。物理模型法从光线与植被—背景交互的机理出发, 利用冠层辐射传输模型刻画反射率与 LAI 的关系, 虽具备较强的时空可迁移性, 但受冠层与背景辐射传输复杂性的制约, 难以兼顾精度与效率 (Han 等, 2024; Verger 等, 2014)。混合法结合了两者优先, 即通过物理模型模拟冠层反射率与 LAI 的关系生成训练样本, 再借助机器学习模型实现 LAI 反演, 近年来得到了广泛应用 (梁顺林等, 2016; Sun 等, 2022)。然而, 受制于传感器波段设置, 已有大多数中高分辨率 LAI 反演研究仍主要依赖可见光、近红外和短波红外波段 (Qu 等, 2014)。由于遥感观测的信息量往往不足以约束复杂的辐射传输过程, 导致反演结果存在较大不确定性 (Zhang 等, 2025)。如何在反演中引入更多敏感且有效的光谱信息, 是提升 LAI 反演精度的重要突破方向。

“红边”定义为红光区外叶绿素吸收减少部位到近红外高反射平台之间 (约 680—760 nm), 健康植物的光谱响应陡然增加的这一窄条带区 (Curran 等, 1991)。由于该区间光谱特征与植被叶绿素含量和冠层结构密切相关, 因此红边被认为是指示作物生理状态 (如叶绿素浓度、氮素水平) 以及冠层结构特征 (如 LAI、叶倾角分布) 的敏感波段 (Dong 等, 2019)。近年来, 随着多颗配置红边波段的中分辨率卫星相继发展, 如高分六号 (GF-6, 中国首颗配置红边波段的农业卫星)、Sentinel-2A/2B, 以及规划中的 Landsat Next 等, 红边在植被参数反演中的应用潜力不断被挖掘, 并逐渐成为作物监测研究的重要关注点 (Bach 和 Mauser, 2003; Zarco-Tejada 等, 2019)。然而, 现有研究对于红边波段是否显著提升 LAI 反演精度的研究结论存在较大差异, 限制了红边信息的深入应用。

一方面, 有研究表明基于红边波段构建的植

被指数能够显著提高 LAI 反演精度, 尤其在高 LAI 区间对冠层饱和效应表现出更强的敏感性, 而在 LAI 低值时也能有效减弱土壤背景的干扰 (Canisius 和 Fernandes, 2012; Pan 等, 2019; Tillack 等, 2014)。此外, 红边植被指数与 LAI 建立的经验关系在不同作物类型间具有较高的一致性, 显示出其在跨作物和跨区域应用中的潜在优势 (Dong 等, 2019; Viña 等, 2011)。另一方面, 也有研究指出, 与传统植被指数相比, 考虑红边波段后的植被指数与 LAI 的相关性提升有限, 未能在不同环境和观测条件下稳定提高反演精度 (Korhonen 等, 2017; Punalekar 等, 2018)。这种差异主要源于已有研究缺乏从物理机理解析红边为 LAI 反演提供的信息量, 导致红边信息未被充分利用, 且研究大多集中在经验关系层面, 依赖于有限的地面观测样本, 其 LAI 反演精度易受研究区域的气候条件、作物类型、冠层结构特征以及观测时相等因素影响而波动。因此, 亟需构建基于物理机理且充分利用红边波段信息的 LAI 反演算法, 并开展系统的定量评估和跨区域、跨作物类型验证, 从而有效提升作物 LAI 反演精度。

针对上述问题, 本研究基于物理模型与机器学习算法结合的混合法 LAI 反演思路, 利用国家生态系统观测研究网络 CNERN (National Ecosystem Research Network of China) 提供的全国主要粮食作物 (水稻、小麦、玉米) LAI 实测数据, 并结合 Sentinel-2 多光谱影像, 系统探索红边波段在作物 LAI 反演中的作用, 并构建耦合红边波段特征的 LAI 反演算法。首先, 通过参数敏感性分析, 从理论上阐明红边波段反射率对 LAI 变化的响应机制。其次, 比较不同机器学习算法对 LAI 与光谱反射率关系的拟合性能, 优选适宜机器学习模型。然后, 评估红边波段与传统波段组合对反演精度的提升效果, 构建基于红边波段优选的 LAI 反演算法。最后, 在不同作物类型和 LAI 区间下开展 LAI 反演算法对比分析, 揭示红边波段对作物 LAI 反演精度的贡献与适用性。

2 研究区与数据

2.1 研究区概况

本研究基于国家生态系统观测研究网络 CNERN (<https://www.cnern.ac.cn/index.action> [2025-09-15])

的站点 LAI 数据，对构建的 LAI 反演算法开展精度评估。CNERN 站网现有 53 个生态站，观测对象涉及森林、草地、农田等生态系统类型，分布于中国 22 个省、自治区和直辖市，其中农田生态系统站 18 个。在农田生态系统站中选择观测对象包含水稻、玉米和小麦 3 种主要粮食作物的站点，最终选取 7 个水稻站点（常熟站、环江站、千烟洲站、

沙坡头站、沈阳站、桃源站、鹰潭站），12 个玉米站点（安塞站、长武站、封丘站、环江站、海伦站、栾城站、临泽站、奈曼站、沙坡头站、沈阳站、桃源站、禹城站），9 个小麦站点（常熟站、长武站、封丘站、栾城站、拉萨站、临泽站、沙坡头站、禹城站、盐亭站）。站点详细信息如表 1 所示。

表 1 研究区各站点及地面 LAI 实测数据详细信息
Table 1 Specific information of selected sites and ground LAI measurements

站点	代码	经度/°E	纬度/°N	年份/年	站点观测作物类型
陕西安塞站	ASA	109.32	36.86	2019—2020	玉米
江苏常熟站	CSA	120.70	31.55	2019—2021	小麦、水稻
陕西长武站	CWA	107.68	35.24	2020	小麦、玉米
河南封丘站	FQA	114.55	35.02	2018—2021	小麦、玉米
广西环江站	HJA	108.32	24.74	2019—2021	玉米、水稻
黑龙江海伦站	HLA	126.97	47.45	2019—2021	玉米
河北栾城站	LCA	114.69	37.89	2019—2021	小麦、玉米
西藏拉萨站	LSA	91.34	29.68	2020—2021	小麦
甘肃临泽站	LZD	100.13	39.35	2019—2021	小麦、玉米
内蒙古奈曼站	NMD	120.72	42.95	2019—2021	玉米
江西千烟洲站	QYA	115.07	26.74	2019—2021	水稻
宁夏沙坡头站	SPD	105.01	37.46	2019—2021	小麦、玉米、水稻
辽宁沈阳站	SYA	123.37	41.52	2019—2021	玉米、水稻
湖南桃源站	TYA	111.44	28.93	2019—2021	玉米、水稻
山东禹城站	YCA	116.57	36.83	2019—2021	小麦、玉米
四川盐亭站	YGA	105.46	31.27	2019—2021	小麦
江西鹰潭站	YTA	116.92	28.21	2019—2020	水稻

2.2 数据及预处理

2.2.1 农作物 LAI 地面实测数据

CNERN 农田站点主要采用叶面积仪扫描法获取作物地面 LAI 数据。具体而言，每个 CNERN 站点包含一个或多个样地，每个样地包含一个或多个 I 级样方，样方大小为 10 m×10 m 到 50 m×50 m 不等。在进行地面 LAI 测量时，根据样方大小，将每个样方划定为 1 m×1 m 到 10 m×10 m 的 II 级采样小区，以小区为单位，每次随机选取 6 个 II 级小区，用叶面积仪扫描法进行 LAI 的测量，最终取 6 个小区 LAI 的均值作为该样方 LAI 实测值（孙鸿烈等，2012；吴冬秀等，2007；徐保东等，2015）。为了获得可靠的地面 LAI 实测数据以及对应的 Sentinel-2 影像，本研究根据以下原则对 2018 年—

2022 年的站点原始数据进行处理与筛选：（1）针对同一个样点包含多个样方且每个样方尺度均小于 20 m×20 m 的情况，为保证地面观测样点与遥感影像像元尺度一致，对该样点内多个样方的 LAI 取均值作为该样点的 LAI；（2）根据农作物生理特征的先验知识（Dong 等，2023；Mercier 等，2020），保留 LAI 范围在 0 到 8 内的实测数据；（3）为了减少农作物生长变化引起的误差，仅保留 LAI 地面测量时间和 Sentinel-2 影像观测时间不超过 7 d 的实测数据；（4）为确保 LAI 实测数据的准确性，根据 LAI 与归一化植被指数 NDVI（Normalized Difference Vegetation Index）的相关性开展质量控制（Ma 和 Liang，2022），在 NDVI 0–1 的取值范围内，以 0.1 为步长将其划分为 10 个区间，每个区间内保留 5%—95% 范围内对应的地面 LAI 实测数据。

基于上述原则，本研究共选取了295条LAI实测数据，其中134条玉米LAI数据，72条水稻LAI数据，89条小麦LAI数据。

2.2.2 Sentinel-2 卫星遥感数据

Sentinel-2是欧洲航天局ESA（European Space Agency）哥白尼计划中的一项重要地球观测任务，由Sentinel-2A和Sentinel-2B两颗卫星组成，两颗卫星协同观测可实现5 d的赤道重访频率。Sentinel-2搭载的多光谱成像仪MSI（Multi-Spectral Instrument）覆盖可见光、近红外及短波红外范围，可提供13个光谱波段的高分辨率影像数据，空间分辨率分别为10 m、20 m和60 m，如图1所示。其中，3个红边波段分别对应波段5—7，空间分辨率为20 m。本研究基于GEE（Google Earth Engine）平台获取各站点大气校正后的地表反射率（Sentinel-2 Level-2A）数据。考虑到波段1（B1，Coastal aerosol）、

波段9（B9，Water vapour）和波段10（B10，Cirrus）常用于大气校正、气溶胶和水汽含量估算以及卷云检测等领域（Zhang等，2023），而波段2（B2，Blue）易受大气粒子散射的影响为反射率引入较大的不确定性（Zhen等，2023），以上四个波段未被本研究使用。剩余8个波段：波段3（B3，Green）、波段4（B4，Red）、波段5（B5，Red-edge1，RE1）、波段6（B6，Red-edge2，RE2）、波段7（B7，Red-edge3，RE3）、波段8A（B8A，Near Infrared，NIR）、波段11（B11，Short Wavelength Infra-Red1，SWIR1）和波段12（B12，Short Wavelength Infra-Red2，SWIR2），则被用于探索农作物LAI反演算法的构建。为保证数据质量与后续处理一致性，利用L2A产品中的QA60波段进行云掩膜处理，并将空间分辨率为10 m的波段统一重采样至20 m，以保证多波段数据之间空间尺度的一致性。




图1 Sentinel-2 MSI传感器光谱波段基本信息，其中灰色波段名称代表该波段未被本研究使用
Fig. 1 The spectral bands of Sentinel-2 MSI, where the gray band names indicate that these bands were not used in this study

3 研究方法

本研究基于混合法反演LAI的思路，在优选机器学习算法及波段组合的基础上，构建耦合红边波段的农作物LAI最优反演算法并评估其效果（图2）。具体流程如下：（1）利用PROSAIL模型生成农作物LAI-冠层反射率模拟数据集，并通过参数敏感性分析厘清各参数对不同波段冠层光谱形

成的贡献度；（2）基于生成的模拟数据集，采用5种机器学习算法分别构建混合法反演模型，根据验证集的结果确定最优机器学习算法；（3）基于优选的机器学习算法，设置8种波段组合分别构建反演模型，优选基于红边波段的LAI反演算法；（4）开展反演模型在不同LAI区间及作物类型下的精度评估，进而对反演算法在不同场景的适用性进行分析。




图2 本研究总体技术路线
Fig. 2 The workflow of this study

3.1 农作物 LAI-冠层反射率模拟数据集生成

3.1.1 PROSAIL 模型参数设置

PROSPECT 模型是 Jacquemoud 和 Baret 基于平板假设构建的叶片尺度辐射传输模型 (Jacquemoud 和 Baret, 1990), 通过模拟入射光在板层间的反射、透射与吸收过程, 输出 400—2500 nm 波段范围内的方向半球反射率与透射率。SAIL 模型作为应用广泛的冠层尺度辐射传输模型, 其假设植物冠层是由水平、均一且无限扩展的各向同性叶片组成的混合体 (Suits, 1971), 通过计算冠层的消光与散射系数, 模拟植被冠层在不同观测和入射条

件下的双向反射特性 (Verhoef, 1984)。考虑到农作物冠层在同一生育期内高度相近、空间分布相对均一, 较好地满足了 SAIL 模型的均质冠层假设, 因此本研究选用 PROSPECT-5 模型与 4SAIL 模型耦合的 PROSAIL 模型 (Feret 等, 2008) 生成模拟数据集。首先, 根据农学先验知识设置 PROSAIL 模型的相关输入参数范围 (Dong 等, 2024; Guo 等, 2024; Liu 等, 2025), 具体细节如表 2 所示。随后, 模拟生成不同参数组合下的 10000 条农作物 LAI-冠层反射率数据集。最后, 为保证模拟数据和卫星观测数据的一致性, 根据 Sentinel-2 卫星的光谱响应函数对模拟的冠层反射率进行光谱重采样。

表 2 PROSAIL 模型输入参数范围

Table 2 The range of input parameter of PROSAIL model

模型	参数(缩写)	单位	范围	分布类型
PROSPECT-5	叶片结构参数(N)	—	1—2	Gauss
	叶绿素含量(C_{ab})	$\mu\text{g}/\text{cm}^2$	10—80	Gauss
	干物质含量(C_m)	g/cm^2	0.001—0.03	Gauss
	等效水厚度(C_w)	cm	0.001—0.05	Uniform
	棕色素含量(C_{bp})	—	0—1	Gauss
	类胡萝卜素含量(C_{ar})	$\mu\text{g}/\text{cm}^2$	1—20	Default (Step=5)
4SAIL	叶面积指数(LAI)	m^2/m^2	0—8	Gauss
	平均叶倾角(ALA)	$^\circ$	10—80	Gauss
	土壤亮度参数($psoil$)	—	0—1	Uniform
	热点参数($hspot$)	—	0.05—0.5	Gauss
	天空漫散射比($Skyl$)	%	10	Constant
	太阳天顶角(ts)	$^\circ$	15—60	Default (Step=5)
	观测天顶角(tto)	$^\circ$	0—30	Default (Step=5)
	相对方位角(psi)	$^\circ$	0—140	Default (Step=20)

3.1.2 参数敏感性分析

植被冠层光谱的形成受到多种生理参数和生化参数的影响，不同参数对光谱特征的贡献存在差异（黄文江 等，2017）。因此，有必要通过敏感性分析对各参数的贡献度进行系统性评估，以厘清不同波段反射率对参数变化的响应规律，进而为后续引入红边波段后的反演效果分析提供理论依据。现有的敏感性分析方法可以分为两类：第1类是全局敏感性分析GSA（Global Sensitivity Analysis），通过同时改变所有输入参数来量化其对输出结果的整体影响。第2类是局部敏感性分析LSA（Local Sensitivity Analysis），在固定其他参数的条件下仅改变一个目标参数，从而揭示该参数对输出的直接影响（Iooss 和 Lemaître，2015）。

本研究分别采取上述两种敏感性分析方法，以全面评估不同参数对冠层光谱形成的影响。首先，利用改进的Sobol算法对PROSAIL模型开展全局敏感性分析（Saltelli 等，2006）。PROSAIL模型共包含14个输入参数，其中叶片棕色素含量（ C_{bp} ）和天空漫散射比（ $Skyl$ ）的取值范围通常固定，因此不纳入敏感性分析，最终基于12个参数和本研究所选取的8个Sentinel-2目标波段，定量评估各

输入参数对冠层反射率的贡献度。随后，对PROSAIL模型开展局部敏感性分析，在固定其他参数的条件下，仅改变LAI的取值，生成不同LAI水平下的模拟冠层光谱，以分析关键波段反射率对LAI动态变化的响应程度。

3.2 混合法反演模型构建及机器学习算法优选

基于已有农作物LAI反演相关研究（Li 等，2025a；Yang 等，2025b），本研究采用随机森林回归RFR（Random Forest Regression）、梯度提升决策树GBDT（Gradient Boosting Decision Tree）、支持向量回归SVR（Support Vector Regression）、高斯过程回归GPR（Gaussian Process Regression）和多层感知机回归MLPR（Multilayer Perceptron Regression）共5种机器学习方法构建反演模型，各算法的具体信息如表3所示。为了确保机器学习算法优选的可靠性，本研究基于不引入红边和引入3条红边两种波段组合，采用5种机器学习算法分别构建LAI反演模型，优选在两种波段组合下反演效果都表现较好的算法。此外，将10000条LAI-冠层反射率模拟数据进行随机采样，按照固定比例将其划分为训练集（70%）和验证集（30%），并将地面实测LAI以及对应的Sentinel-2数据作为测试集。

表3 5种机器学习算法的简介

Table 3 Introduction of five machine learning algorithms

算法	简介	主要参数	参考文献
随机森林回归(RFR)	RFR是由多个决策树组成的回归模型。其基本思想是通过对训练样本进行有放回的随机抽样,并在每棵树的构建过程中随机选择部分特征进行分裂,形成多个相互独立的决策树。最终预测结果由所有树的平均值给出,从而有效降低单棵决策树过拟合的风险,提高模型的泛化能力	$n_estimators$:决策树的数量 max_depth :最大树深度,用于控制每棵决策树的最大深度,防止模型过拟合 $min_samples_split$:最小分裂样本数,表示节点再划分所需的最小样本数	(Kang等,2021)
梯度提升决策树(GBDT)	GBDT是一种基于提升(Boosting)思想的集成学习算法,通过迭代方式不断训练新的弱学习器来拟合前一轮的残差,在每一步迭代中通过最小化损失函数的负梯度方向来更新模型。GBDT在处理非线性回归问题时表现出较强的拟合能力和灵活性,可有效捕捉复杂的特征关系	$n_estimators$:决策树的数量 $learning_rate$:学习率,表示每次迭代更新的步长 max_depth :最大树深度,限制每棵树的深度,控制模型复杂度 $min_samples_split$:最小分裂样本数,表示节点分裂所需的最少样本数	(Chen等,2024)
支持向量回归(SVR)	SVR是基于统计学习理论的非线性回归方法,其核心思想是将输入数据映射到高维特征空间,并在该空间内构建一个最优回归超平面。通过引入核函数,SVR能够处理线性不可分问题,同时通过 ϵ -不敏感损失函数控制预测误差范围,在小样本、高维度和非线性问题中具有较好的泛化性能	C :惩罚系数,模型对误差的容忍度 $epsilon$:损失容忍范围,表示在误差小于 $epsilon$ 时不计算损失 $kernel$:核函数类型,定义数据映射到高维空间的方式	(Liu等,2024)
高斯过程回归(GPR)	GPR是一种基于贝叶斯理论的非参数化方法,通过高斯分布描述函数空间的先验分布,并结合观测数据计算后验分布。GPR在数据量较小的情况下表现出较高的精度和稳定性,但计算复杂度较高	$kernel$:核函数,用于描述输入样本间的相似性结构 $alpha$:噪声项,用于控制模型对观测噪声的鲁棒性 $length_scale$:特征长度尺度,控制输入变量影响范围	(Jin等,2024)

算法	简介	主要参数	参考文献
多层感知机回归(MLPR)	MLPR 是一种前馈型人工神经网络,由输入层、一个或多个隐藏层及输出层构成。通过非线性激活函数实现输入特征到输出结果的复杂映射,并通过反向传播算法不断调整网络权重,以最小化预测误差。MLPR 在处理高维、非线性问题时具有较强的拟合能力和灵活性	<i>hidden_layer_sizes</i> :隐藏层神经元数量,用于控制每层神经元个数与层数 <i>activation</i> :激活函数,决定神经元的非线性映射方式 <i>solver</i> :优化算法,用于控制权重更新的优化方式 <i>alpha</i> :正则化系数,用于控制模型权重的惩罚项,防止过拟合	(Wang等,2022)

本研究采用 Python 中的 Scikit-learn 软件包进行模型构建、评估以及数据分析和可视化,并使用贝叶斯优化算法为每个机器学习模型选择最佳参数,其中,只对表格中对模型结果影响较大的主要参数进行调优,其余参数设置为默认值。

3.3 基于波段组合优选的最优反演算法构建

基于优选出的机器学习算法,进一步开展波段组合优选,以确定适用于农作物 LAI 反演的最优波段。本研究设计了两类波段组合方案,第1类是不包含红边波段的基础波段组合 (Green、Red、NIR、SWIR1、SWIR2),第2类是在基础波段组合上分别引入单红边、双红边和三红边波段,两类共构成 8 种波段组合 (表 4)。利用机器学习算法分别训练 LAI 与波段反射率拟合关系,对比不同波段组合下模型的反演效果,进而构建农作物 LAI 反演最优算法。

表 4 波段组合名称及所包含具体波段

Table 4 Band combinations and corresponding bands	
组合名称	包含波段名称
Z1	Green、Red、NIR、SWIR1、SWIR2
Z2	Green、Red、NIR、SWIR1、SWIR2 + RE1 + RE2 + RE3
Z3	Green、Red、NIR、SWIR1、SWIR2 + RE1
Z4	Green、Red、NIR、SWIR1、SWIR2 + RE2
Z5	Green、Red、NIR、SWIR1、SWIR2 + RE3
Z6	Green、Red、NIR、SWIR1、SWIR2 + RE1 + RE2
Z7	Green、Red、NIR、SWIR1、SWIR2 + RE1 + RE3
Z8	Green、Red、NIR、SWIR1、SWIR2 + RE2 + RE3

3.4 精度评估

为构建耦合红边波段的农作物 LAI 反演方法,本研究首先基于模拟数据集对 5 种机器学习算法进行训练与验证,从而筛选出最佳机器学习算法,并利用实测 LAI 与 Sentinel-2 影像构建的测试集对各模型进行检验,以评估其泛化能力。随后,基

于最优机器学习算法,对比不包含红边波段以及包含不同红边波段组合的反演效果,优选出最佳波段组合,进而确定农作物 LAI 最优反演模型。模型效果的评价指标包括相关性决定系数 R^2 (Coefficient of Determination)、偏差 (Bias)、平均绝对误差 MAE (Mean Absolute Error) 和均方根误差 RMSE (Root Mean Square Error)。

此外,为进一步评估所构建最优 LAI 反演模型的适用性与稳定性,从以下两方面分析模型在不同情景下的表现:(1) 不同 LAI 区间的反演精度评估:将实测 LAI 划分为多个区间 (0—1, 1—2, 2—3, 3—4, 4—5, >5),分别计算各区间的 Bias 和 RMSE,评估模型在不同 LAI 水平下的表现,以探讨红边波段对不同 LAI 区间反演效果的影响;(2) 不同作物类型的反演精度评估:以小麦、玉米和水稻 3 种农作物为研究对象,比较模型在不同作物上的反演精度差异,以揭示模型在不同作物类型 LAI 反演中的适用性。

4 结果与分析

4.1 参数敏感性分析

图 3 (a) 展示了不同波段反射率对 PROSAIL 模型输入参数的全局敏感性分析结果。由图 3 (a) 可知,除两个短波红外波段外,叶绿素含量 (C_{ab})、平均叶倾角 (ALA) 和 LAI 等 3 个参数在所有波段上的综合贡献度超过 70%,说明可见光至近红外波段反射率主要受以上 3 个参数的影响。具体而言, C_{ab} 在 Green 和 Red 波段的贡献率分别达到 42.3% 和 38.9%,是影响可见光反射率的主导因子。相对而言,ALA 和 LAI 在红边及近红外波段表现出更强的敏感性。在 RE2、RE3 和 NIR 波段,ALA 与 LAI 的总贡献率均超过 70%,其中 LAI 在 RE2 和 RE3 上的贡献率分别为 46.6% 和 47.2%,表明较长的红边波段对冠层结构参数较为敏感。在

短波红外波段范围内, 等效水厚度 (C_w) 逐渐成为影响模型输出的重要参数, 在 SWIR1 和 SWIR2 处的贡献率分别达到了 76.5% 和 66.5%, 反映了植被水分在短波红外区的强烈吸收特性。综合而言,

虽然不同参数在各光谱区域表现出差异化的敏感性,但不同红边波段对LAI变化都具有一定的敏感性,为耦合红边波段提升LAI反演精度提供了理论基础。




图3 Sentinel-2不同波段反射率对PROSAIL模型输入参数的敏感性分析及对LAI变化响应

Fig. 3 Sensitivity analysis of Sentinel-2 different band reflectance to the input parameters of the PROSAIL model and the response of different band to changes in LAI

为进一步分析各波段反射率对 LAI 变化的响应,在固定其他参数条件下,只使用 LAI 单参数驱动 PROSAIL 模型模拟冠层反射率,结果如图 3(b) 所示。图中灰色矩形表示 Sentinel-2 的 Red、RE1、RE2、RE3 和 NIR 波段的光谱范围,可直观体现这 5 个波段所捕捉的光谱变化特征。由图可知,随着 LAI 的增加,冠层光谱呈现出整体上升的趋势,尤其是在 700—900 nm 范围内,冠层光谱抬升趋势明显。在红边区,不同波段的光谱响应差异较为显著。其中,RE1 波段反射率随着 LAI 的增加而逐渐下降,RE2 波段反射率整体呈现缓慢上升趋势,而 RE3 波段反射率则表现出较强的敏感性。具体而言,RE3 波段反射率在中低值 LAI 区间 ($0.1 < \text{LAI} < 4$) 随 LAI 的变化最为显著,而当 $\text{LAI} > 4$ 时,其反射率波动趋于平缓,对高值 LAI 的敏感性显著减弱。相比之下,RE1 和 RE2 波段的敏感性随 LAI 增加逐渐降低,其中 RE2 的响应曲线变化相对平缓。因此,有必要在参数敏感性分析的基础上,合理结合不同红边波段的特点,发展针对农作物 LAI 反演的优化算法,从而提高 LAI 反演精度。

4.2 不同机器学习算法的反演效果对比

分别选用无红边波段 (Z1) 和引入 3 个红边波段 (Z2) 两种组合, 对 5 种机器学习算法进行模型训练、验证和测试, 以评估不同算法的 LAI 反演效果。其中, 验证集评估结果主要体现模型的拟合效果, 而测试集评估结果能够更真实地反映模型的泛化能力。基于图 4 可看出, 在验证集上 5 种方法的精度结果存在明显差异, MLPR 在两种波段组合下均表现最优, GPR 次之, SVR 居中, GBDT 与 RFR 精度相对较低。进一步在测试集上开展精度评价显示, 在 Z2 组合下, MLPR ($R^2=0.757$, Bias=-0.142, MAE=0.706, RMSE=0.902) 和 GPR ($R^2=0.748$, Bias=-0.461, MAE=0.809, RMSE=1.079) 的反演效果较好, 显著优于其他 3 种方法 (R^2 : 0.520—0.588, Bias: -0.237—0.039, MAE: 0.897—1.021, RMSE: 1.222—1.264)。其中, MLPR 相较于精度最差的 RFR, R^2 提升了 45.5%, RMSE 降低了 28.2%, 进一步验证了其在非线性特征学习及参数反演上的优势 (Ercanli 等, 2018; Li 等, 2025b)。此外, 对比同一算法下 Z1 和 Z2 两种组合反演精度

的差异,可以发现引入红边波段后,5种方法的精度在验证集和测试集上均有一定程度的提升。其中,SVR的提升幅度最大,在测试集上, R^2 升高了10.6%,RMSE降低了22.4%,而MLPR虽提升

幅度相对有限,但在两种波段组合下均保持最高精度,显示其较强的稳健性。因此,本研究选用MLPR作为后续混合法LAI反演模型的最优算法。




图4 Z1和Z2波段组合下基于5种机器学习算法构建的LAI反演模型在验证集及测试集的精度

Fig. 4 The accuracy of LAI retrieval models developed based on five machine learning algorithms on validation and test datasets using Z1 and Z2 band combinations

图5展示了MLPR模型预测LAI与实测LAI的散点分布特征。从结果可以看出,模型在验证集和测试集上的表现较为一致。随着红边波段的引入,模型精度得到一定的提升,其中 R^2 在验证集和测试集上分别提高了2.4%和1.4%,同时RMSE分别降低了4.0%和7.8%,MAE分别降低了5.0%和6.6%,说明红边波段的引入有助于提升LAI反演的精度。值得注意的是,引入红边波段后,高

值区间中普遍存在的LAI高值低估现象都有所缓解(|Bias|减小),高值样本的预测结果更趋近于1:1拟合线。这表明红边波段的引入能够在一定程度上缓解高LAI情况下的饱和效应,从而提升模型对高密度农作物冠层的表征能力。然而,图5也显示了引入全部红边波段对于LAI反演精度的提升较为有限,不同红边波段组合能否进一步提升LAI反演精度,仍需开展较为深入的研究。




图5 Z1和Z2波段组合下基于MLPR算法构建的LAI反演模型在验证集和测试集上散点分布图

Fig. 5 Scatter plots of LAI retrieval models developed with the MLPR algorithm on validation dataset and test dataset using Z1 and Z2 band combinations

4.3 不同波段组合的反演效果对比

为了进一步探讨不同红边波段对反演精度的影响，本研究基于MLPR算法分析不同波段组合下LAI反演模型的精度（图6）。引入红边波段后，整体反演精度（ R^2 : 0.750—0.784，RMSE: 0.826—0.979）均优于不使用红边波段的情况（ $R^2=0.747$ ，RMSE=0.979），表明红边波段的引入可以有效提升LAI反演精度。然而，红边波段的引入数量以及具体选择的波段类型都会影响LAI反演精度。具体而

言，在单红边波段组合（Z3—Z5）中，引入RE3（Z5）的反演效果最优（ $R^2=0.759$ ，RMSE=0.947）；而当引入两个红边波段（Z6—Z8）时，引入RE1和RE3波段（Z7）模型的表现最优（ $R^2=0.784$ ，RMSE=0.826）。进一步地，同时引入3个红边波段时，LAI反演模型精度（ $R^2=0.757$ ，RMSE=0.902）和引入两个红边波段的Z7组合相比反而出现下降。总体而言，在所有波段组合中，Z7的反演效果最优，说明同时引入RE1与RE3对提升模型精度贡

献最大,与Z1相比, R^2 提升了4.9%,RMSE降低了15.6%。结合4.1节的敏感性分析结果可知,RE1和RE3反射率随LAI变化呈显著波动,对LAI变化较为敏感,而RE2反射率随LAI变化波动较为平缓,对LAI的响应较弱。因此,单独使用或额外引入RE2所带来的信息增益有限,甚至可能引入噪声,从而降低模型精度。综上,基于RE1和RE3红边波段(Z7)组合构建的MLPR模型在所有波段组合中表现最佳,被选为最优农作物LAI反演算法,用于后续模型不同情景下适用性的评估。




图6 基于MLPR算法和不同波段组合构建的LAI反演算法精度评价结果


Fig. 6 Evaluation of LAI retrieval models based on the MLPR algorithm and different band combinations

4.4 LAI反演模型在不同情景下的表现


4.4.1 不同LAI区间的反演精度对比

基于构建的反演模型生成的LAI预测值和真实值(图7(a)(b))可知,引入红边波段后,模型

在低值高估和高值低估方面均得到一定程度缓解,表明红边波段的引入可以有效缓解LAI反演的系统性偏差。进一步从分区指标来看(图7(c)(d)),在Bias方面,除LAI 0—1区间外,其余区间|Bias|均有所下降,其中LAI 3—4、4—5和>5区间的下降幅度最为显著,|Bias|分别降低76.2%、52.2%和26.4%。这表明红边波段能够有效降低LAI反演模型在中高值区间的系统性偏差。在RMSE方面,引入红边后,LAI 0—1、3—4、4—5和>5区间的RMSE分别下降40.4%、5.7%、41.4%和24.9%,但在LAI 1—2和2—3区间的RMSE则有所升高。该现象可归因于以下两方面因素:一方面,红边表征的是叶片在红波段强吸收和近红外波段强反射之间的过渡特征,因此当LAI较低、冠层尚未完全形成时,叶片数量较少,红边对低值LAI变化的响应不敏感(Lee等,2004)。另一方面,低值LAI区间的植被覆盖度较低,土壤背景及其他外界因素的干扰易向红边波段反射率中引入噪声,使得红边波段在该区间对LAI的表征能力下降(Qiao等,2024)。因此,在LAI低值及部分中值区间,红边波段的引入对反演模型信息量的贡献有限(Cui和Kerekes,2018)。在中高值区间,随着LAI增大,红边波段对反演精度的提升作用更为显著。然而,当LAI到达一定高值(>5)时,由于冠层过于密集,受限光学信息的饱和效应,红边波段不足以提供新的有效信息量,使其对高值低估的缓解作用逐渐减弱。



(a) Z1波段组合下模型总体精度
(a) Overall accuracy of the model using Z1



(b) Z7波段组合下模型总体精度
(b) Overall accuracy of the model using Z7




图7 Z1和Z7波段组合下,基于MLPR算法构建的LAI反演模型精度评价(n 表示该区间地面样本数量)

Fig. 7 Performance of MLPR-based LAI retrieval models using Z1 and Z7 band combinations (n represents the number of ground samples in each interval)

4.4.2 不同作物类型的反演精度对比

依据不同作物类型的反演精度对比结果(图8)可知,在Z7波段组合下,玉米的LAI反演精度最高($R^2=0.847$, $Bias=-0.341$, $MAE=0.658$, $RMSE=0.864$),水稻($R^2=0.778$, $Bias=-0.069$, $MAE=0.576$, $RMSE=0.775$)和小麦($R^2=0.723$, $Bias=-0.151$, $MAE=0.692$, $RMSE=0.857$)的反演精度次之。引入红边波段后,3类作物的反演精度均有所提升,其中玉米的提升效果最为显著(R^2 提升

17.9%, $RMSE$ 降低29.1%),水稻的提升幅度相对有限(R^2 提升0.8%, $RMSE$ 降低6.9%),小麦则处于中间水平(R^2 提升1.2%, $RMSE$ 降低10.0%)。以上结果表明,不同作物的冠层结构差异决定了红边波段对LAI变化的敏感性与响应强度,这种差异进一步导致红边信息对不同作物LAI反演精度提升效果的不同表现。相较于小麦和水稻,冠层分层明显、结构复杂的玉米在引入红边波段后表现出最显著的精度提升。




图8 Z1和Z7波段组合下,基于MLPR算法构建的模型在不同作物类型的LAI反演精度

Fig. 8 Evaluation of LAI retrievals based on MLPR algorithm for different crop types using Z1 and Z7 band combinations

5 讨论

针对目前中高分辨率农作物LAI反演结果存在

较大不确定性的问题(刘良云, 2014; 梁顺林等, 2016),本研究基于混合法LAI反演思路,系统评估了机器学习算法以及红边波段在农作物LAI反演

中的效果,并构建了耦合红边波段特征的LAI反演算法。研究结果显示,虽然引入红边波段可提升LAI反演精度,但在不同的应用情景下模型的适用性出现较大差异。因此,后续讨论将重点围绕红边波段的选择策略、敏感性特征及其在不同场景下的表现进行系统分析,以探讨红边波段提升农作物LAI反演精度的潜在机理。

在模型方法与波段组合的优选方面,MLPR算法在训练集、验证集和测试集上均表现最佳,显示出较强的非线性拟合与泛化能力(图4),表明其在作物LAI反演应用中的巨大潜力。相较于传统的线性回归或经验模型,MLP能够通过多层非线性映射充分挖掘光谱与LAI之间复杂的高维关系,自动学习不同波段间的特征交互与非线性响应规律。此外,其较强的自适应特征提取能力可有效捕捉作物冠层结构、叶片角度分布等生物物理特征对光谱反射的综合影响,从而在多波段、多作物类型条件下均表现出较高的稳定性与鲁棒性(Wang等,2022)。同时,引入红边波段不仅显著提升了LAI反演精度,还有效缓解了高值区间的系统性低估问题(图5)。其原因主要在于红边波段对叶绿素含量和叶面积变化较为敏感,能够在一定程度上缓解可见光和近红外波段的饱和限制(Bramich等,2021)。值得注意的是,由于不同红边波段反射率对LAI变化的敏感性存在差异,导致RE1和RE3对模型精度提升作用最显著,而RE2对模型精度提升效果有限,甚至可能在部分LAI区间引入噪声,导致反演精度下降(图6)。因此,针对农作物LAI反演而言,合理选择红边特征比仅仅增加红边波段数量对于精度提升更为显著。

基于CNERN全国站点观测的主粮作物LAI数据集,对利用红边波段构建的LAI反演算法在不同场景进行评估,进一步揭示了引入红边波段的必要性(图7)。虽然在低值LAI区间,引入红边波段对LAI反演精度的提升较为有限,但在中高值区间,红边波段的引入可显著降低LAI反演的系统性偏差及不确定性,并有效缓解了饱和效应。这一结果与已有研究的结论一致(Brantley等,2011; Pu等,2003; Tillack等,2014),表明红边波段对高LAI植被更为敏感,能够在传统波段饱和的情况下,依然保持对LAI变化的较强响应能力。而当LAI>5时,其作用逐渐减弱,呈现出“阈值效应”,表明在植被浓密的情况下,光学信息不足以继续

提供更多有效结构信息(Gao等,2024)。此外,不同作物类型反演精度的比较进一步揭示了红边波段作用于不同作物LAI反演时效果的差异。红边波段对玉米LAI反演精度的提升最为显著,其次为小麦,而水稻的改善最弱(图8),这可能与三种作物在冠层结构和叶片空间分布上的差异密切相关(王丹彤和屈永华,2024)。具体而言,玉米植株较高且冠层垂直分层明显,使其对红边波段的光谱响应更为敏感,因此引入红边后模型性能显著提升(Yang等,2025a)。相比之下,小麦植株较低矮且分布较为分散,尽管其因分蘖会形成一定的株丛结构,但整体冠层分布较为分散,对红边波段的响应较弱,导致红边信息对LAI反演的贡献有限(Wang等,2024)。对于水稻而言,其冠层水平分布密集、叶片较窄,且不同生育期受水土混合背景影响较大,容易在红边波段引入额外噪声(Wu等,2024; Xing等,2022)。此外,在未引入红边波段时,水稻LAI反演精度已处于较高水平,因此红边波段的增益作用相对较弱。

需要指出的是,本研究仍存在一定局限性,需要在未来研究中进行改进。首先,训练数据主要来源于通用的农作物PROSAIL模拟数据集,缺乏针对特定作物的参数设置,可能在一定程度上限制模型的精度,未来研究可通过结合田间实测生理生化数据,对模型输入参数进行优化以及特定作物参数的设置,以提升模拟数据与实际场景的一致性。其次,由于本研究采用的PROSAIL模型未考虑冠层聚集效应,因此与地面实测LAI相比,基于红边波段构建的LAI反演算法仍存在LAI预测系统性偏低的问题。未来可进一步引入考虑冠层非均匀分布的三维辐射传输模型(Gastellu-Etchegorry等,1996; Qi等,2019; 张虎等,2023),以更真实地模拟作物冠层的空间结构特征。同时,结合多角度遥感观测数据,可增强对冠层散射与聚集效应的刻画能力,从而更有效缓解系统性偏差,进而提升LAI反演精度。最后,本研究仅选取了单一传感器(Sentinel-2)影像,未来可考虑多源遥感数据(如GF-6、RapidEye等)的协同反演,进一步提升模型的稳定性与跨区域适用性(Chen等,2025; Fang等,2019b; Wan等,2024)。

6 结 论

本研究以联合物理模型和机器学习算法的混

合法 LAI 反演为基本思路, 通过利用 PROSAIL 模型模拟 LAI 与冠层反射率数据集, 结合 CNERN 站网提供的全国多时相多作物类型的地面 LAI 实测数据以及 Sentinel-2 影像, 系统评估了不同机器学习算法及波段组合在农作物 LAI 反演中的效果, 构建了融合红边波段特征的农作物 LAI 最优反演算法, 并对其在不同情景下的适用性进行分析, 主要结论如下:

(1) 在 5 种机器学习方法中, 基于 MLPR 模型构建的 LAI 反演算法在未引入红边波段以及引入 3 个红边波段的两种情景下, 在验证集和测试集上均表现最佳。这表明 MLPR 算法在非线形特征学习方面具有优势, 能够有效刻画 LAI 与冠层反射率之间的非线性关系;

(2) 引入红边波段整体上提高了 LAI 反演精度, 尤其在缓解高值低估方面作用突出。然而, 不同红边波段的贡献存在差异, 其中引入 RE1 和 RE3 波段对反演精度提升效果最为显著, 而 RE2 提升效果有限。因此, 本研究基于 MLPR 算法和耦合 RE1 与 RE3 的波段组合构建了农作物 LAI 反演算法 ($R^2=0.784$, Bias=-0.162, MAE=0.635, RMSE=0.826);

(3) 在不同场景下, 红边对反演模型的贡献表现出较大差异性: 引入红边对 LAI 中高值区间的精度提升作用最为显著 ($4 < \text{LAI} < 5$ 区间的 |Bias| 和 RMSE 分别下降 52.2% 和 41.4%); 而在低值区间, 引入红边波段对模型反演精度的改善效果有限。在不同作物类型中, 红边信息对冠层结构复杂的作物更为敏感, 引入红边波段对玉米的反演精度改善最为明显 (R^2 提升 17.9%, RMSE 降低 29.1%), 其次为小麦, 对水稻反演精度改善效果最小。

综上所述, 在优选机器学习方法的基础上, 合理地选择红边波段组合可有效提升农作物 LAI 反演精度。未来研究可结合多源遥感数据与考虑冠层聚集效应的机理模型, 进一步拓展耦合红边波段的 LAI 算法在不同作物类型和区域条件下的适用性。

志 谢 感谢国家生态系统观测研究网络 (CNERN) 提供的作物 LAI 地面实测数据。

参考文献 (References)

- Bach H and Mauser W. 2003. Methods and examples for remote sensing data assimilation in land surface process modeling. *IEEE Transactions on Geoscience and Remote Sensing*, 41(7): 1629-1637 [DOI: 10.1109/TGRS.2003.813270]
- Bramich J, Bolch C J S and Fischer A. 2021. Improved red-edge chlorophyll-a detection for Sentinel 2. *Ecological Indicators*, 120: 106876 [DOI: 10.1016/j.ecolind.2020.106876]
- Brantley S T, Zinnert J C and Young D R. 2011. Application of hyperspectral vegetation indices to detect variations in high leaf area index temperate shrub thicket canopies. *Remote Sensing of Environment*, 115(2): 514-523 [DOI: 10.1016/j.rse.2010.09.020]
- Canisius F and Fernandes R. 2012. Evaluation of the information content of Medium Resolution Imaging Spectrometer (MERIS) data for regional leaf area index assessment. *Remote Sensing of Environment*, 119: 301-314 [DOI: 10.1016/j.rse.2011.10.013]
- Chen A, Xu C, Zhang M, Guo J, Xing X Y, Yang D, Xu B and Yang X C. 2024. Cross-scale mapping of above-ground biomass and shrub dominance by integrating UAV and satellite data in temperate grassland. *Remote Sensing of Environment*, 304: 114024 [DOI: 10.1016/j.rse.2024.114024]
- Chen J H, Xu H Q and Tang F. 2025. Coupling spectral indices and machine learning to compare GF-6 and Sentinel-2A data in forest health monitoring. *Chinese Geographical Science*, 35(3): 581-599 [DOI: 10.1007/s11769-025-1523-4]
- Chen J M and Black T A. 1992. Defining leaf area index for non-flat leaves. *Plant, Cell and Environment*, 15(4): 421-429 [DOI: 10.1111/j.1365-3040.1992.tb00992.x]
- Chen J M, Ju W M, Ciais P, Viovy N, Liu R G, Liu Y and Lu X H. 2019. Vegetation structural change since 1981 significantly enhanced the terrestrial carbon sink. *Nature Communications*, 10(1): 4259 [DOI: 10.1038/s41467-019-12257-8]
- Cui Z Y and Kerekes J P. 2018. Potential of red edge spectral bands in future Landsat satellites on agroecosystem canopy green leaf area index retrieval. *Remote Sensing*, 10(9): 1458 [DOI: 10.3390/rs10091458]
- Curran P J, Dungan J L, Macler B A and Plummer S E. 1991. The effect of a red leaf pigment on the relationship between red edge and chlorophyll concentration. *Remote Sensing of Environment*, 35(1): 69-76 [DOI: 10.1016/0034-4257(91)90066-F]
- Djamai N, Fernandes R, Sun L X, Hong G, Brown L A, Morris H and Dash J. 2025. On the consistency and stability of vegetation biophysical variables retrievals from Landsat-8/9 and Sentinel-2. *ISPRS Journal of Photogrammetry and Remote Sensing*, 224: 329-347 [DOI: 10.1016/j.isprsjprs.2025.04.006]
- Dong M X, Liu S Y, Jiang R B, Qi J B, de Solan B, Comar A, Li L Y, Li W J, Ding Y F and Baret F. 2024. Comparing and combining data-driven and model-driven approaches to monitor wheat green area index with high spatio-temporal resolution satellites. *Remote Sensing of Environment*, 305: 114118 [DOI: 10.1016/j.rse.2024.114118]

- Dong T F, Liu J, Liu J G, He L M, Wang R, Qian B D, McNairn H, Powers J, Shi Y C, Chen J M and Shang J L. 2023. Assessing the consistency of crop leaf area index derived from seasonal Sentinel-2 and Landsat 8 imagery over Manitoba, Canada. *Agricultural and Forest Meteorology*, 332: 109357 [DOI: 10.1016/j.agrformet.2023.109357]
- Dong T F, Liu J G, Shang J L, Qian B D, Ma B L, Kovacs J M, Walters D, Jiao X F, Geng X Y and Shi Y C. 2019. Assessment of red-edge vegetation indices for crop leaf area index estimation. *Remote Sensing of Environment*, 222: 133-143 [DOI: 10.1016/j.rse.2018.12.032]
- Ercanlı İ, Günlü A, Şenyurt M and Keleş S. 2018. Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey. *Forest Ecosystems*, 5(1): 29 [DOI: 10.1186/s40663-018-0149-8]
- Fang H L, Baret F, Plummer S and Schaepman-Strub G. 2019a. An overview of global leaf area index (LAI): methods, products, validation, and applications. *Reviews of Geophysics*, 57(3): 739-799 [DOI: 10.1029/2018RG000608]
- Fang H L, Zhang Y H, Wei S S, Li W J, Ye Y C, Sun T and Liu W W. 2019b. Validation of global moderate resolution leaf area index (LAI) products over croplands in northeastern China. *Remote Sensing of Environment*, 233: 111377 [DOI: 10.1016/j.rse.2019.111377]
- Feret J B, François C, Asner G P, Gitelson A A, Martin R E, Bidet L P R, Ustin S L, Le Maire G and Jacquemoud S. 2008. PROSPECT-4 and 5: advances in the leaf optical properties model separating photosynthetic pigments. *Remote Sensing of Environment*, 112(6): 3030-3043 [DOI: 10.1016/j.rse.2008.02.012]
- Fernandes R, Brown L, Canisius F, Dash J, He L M, Hong G, Huang L, Le N Q, MacDougall C, Meier C, Darko P O, Shah H, Spafford L and Sun L X. 2023. Validation of Simplified Level 2 Prototype Processor Sentinel-2 fraction of canopy cover, fraction of absorbed photosynthetically active radiation and leaf area index products over North American forests. *Remote Sensing of Environment*, 293: 113600 [DOI: 10.1016/j.rse.2023.113600]
- Gao S, Yan K, Liu J X, Pu J B, Zou D X, Qi J B, Mu X H and Yan G J. 2024. Assessment of remote-sensed vegetation indices for estimating forest chlorophyll concentration. *Ecological Indicators*, 162: 112001 [DOI: 10.1016/j.ecolind.2024.112001]
- Gastellu-Etcheberry J P, Demarez V, Pinel V and Zagolski F. 1996. Modeling radiative transfer in heterogeneous 3-D vegetation canopies. *Remote Sensing of Environment*, 58(2): 131-156 [DOI: 10.1016/0034-4257(95)00253-7]
- Guo A T, Huang W J, Qian B X, Ye H C, Jiao Q J, Cheng X Z and Ruan C. 2024. A hybrid model coupling PROSAIL and continuous wavelet transform based on multi-angle hyperspectral data improves maize chlorophyll retrieval. *International Journal of Applied Earth Observation and Geoinformation*, 132: 104076 [DOI: 10.1016/j.jag.2024.104076]
- Han Y L, Dong Y Y, Zhu Y N and Huang W J. 2024. Remote sensing inversion of vegetation parameters with IPROSAIL-Net. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5501916 [DOI: 10.1109/TGRS.2023.3344188]
- He M, Wen J G, You D Q, Tang Y, Wu S B, Hao D L, Lin X W and Gong Z R. 2022. Review of forest Leaf Area Index retrieval over rugged terrain based on remotely sensed data. *National Remote Sensing Bulletin*, 26(12): 2451-2472 (贺敏, 闻建光, 游冬琴, 唐勇, 吴胜标, 郝大磊, 林兴稳, 龚张融. 2022. 山地森林叶面积指数(LAI)遥感估算研究进展. *遥感学报*, 26(12): 2451-2472) [DOI: 10.11834/jrs.20210244]
- Huang W J, Kong W P, Dong Y Y, Ye H C, Peng D L, Xie Q Y, Xing N C, Jiao Q J and Zhou X F. 2017. Quantitative Retrieval of Physical and Chemical Parameters of Crops through Remote Sensing. Beijing: Science Press (黄文江, 孔维平, 董莹莹, 叶回春, 彭代亮, 谢巧云, 邢乃琛, 焦全军, 周贤锋. 2017. 作物理化参数遥感定量反演. 北京: 科学出版社)
- Iooss B and Lemaître P. 2015. A review on global sensitivity analysis methods//Dellino G, Meloni C, eds. *Uncertainty Management in Simulation-Optimization of Complex Systems: Algorithms and Applications*. New York: Springer: 101-122 [DOI: 10.1007/978-1-4899-7547-8_5]
- Jacquemoud S and Baret F. 1990. PROSPECT: a model of leaf optical properties spectra. *Remote Sensing of Environment*, 34(2): 75-91 [DOI: 10.1016/0034-4257(90)90100-Z]
- Jin W J, Zhang Z W, Wu T Z, Meng K, Wang Q, Tong W T, Wang C, Yin G F and Xu B D. 2024. Retrieval of leaf area index from MODIS surface reflectance by incorporating the subpixel information from decametric-resolution data. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 1-17 [DOI: 10.1109/TGRS.2024.3373629]
- Kang Y H, Ozdogan M, Gao F, Anderson M C, White W A, Yang Y, Yang Y and Erickson T A. 2021. A data-driven approach to estimate leaf area index for Landsat images over the contiguous US. *Remote Sensing of Environment*, 258: 112383 [DOI: 10.1016/j.rse.2021.112383]
- Korhonen L, Hadi, Packalen P and Rautiainen M. 2017. Comparison of Sentinel-2 and Landsat 8 in the estimation of boreal forest canopy cover and leaf area index. *Remote Sensing of Environment*, 195: 259-274 [DOI: 10.1016/j.rse.2017.03.021]
- Lee K S, Cohen W B, Kennedy R E, Maersperger T K and Gower S T. 2004. Hyperspectral versus multispectral data for estimating leaf area index in four different biomes. *Remote Sensing of Environment*, 91(3/4): 508-520 [DOI: 10.1016/j.rse.2004.04.010]
- Li D, Croft H, Duveiller G, Schreiner-McGraw A P, Belwalkar A, Cheng T, Zhu Y, Cao W X and Yu K. 2025a. Global retrieval of canopy chlorophyll content from Sentinel-3 OLCI TOA data using a two-step upscaling method integrating physical and machine learning models. *Remote Sensing of Environment*, 328: 114845 [DOI: 10.1016/j.rse.2025.114845]
- Li J, Xiao Z Q, Sun R, Song J L and Shi C H. 2025b. Retrieval of leaf area index from the Landsat surface reflectance using multi-task adversarial transfer learning. *International Journal of Digital Earth*, 18(1): 2520002 [DOI: 10.1080/17538947.2025.2520002]

- Li X L, Dong Y Y, Zhu Y N and Huang W J. 2023. Enhanced leaf area index estimation with CROP-DualGAN network. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5514610 [DOI: 10.1109/TGRS.2022.3230354]
- Liang S L, Chen X N, Chen Y, Cheng J, Jia K, Jiang B, Li B, Liu Q, Ma H, Song L L, Tang B H, Xu J L, Yao Y J, Yuan W P, Zhang X T, Zhang Y Z, Zhao X and Zhou J. 2023. Updates on global land surface satellite (GLASS) products suite. *National Remote Sensing Bulletin*, 27(4): 831-856 (梁顺林, 陈晓娜, 陈琰, 程洁, 贾坤, 江波, 李冰, 刘强, 马晗, 宋柳霖, 唐伯惠, 徐蒋磊, 姚云军, 袁文平, 张晓通, 张玉珍, 赵祥, 周纪. 2023. 陆表卫星遥感 GLASS 产品集的研发新进展. *遥感学报*, 27(4): 831-856) [DOI: 10.11834/jrs.20232462]
- Liang S L, Cheng J, Jia K, Jiang B, Liu Q, Liu S H, Xiao Z Q, Xie X H, Yao Y J, Yuan W P, Zhang X T and Zhao X. 2016. Recent progress in land surface quantitative remote sensing. *Journal of Remote Sensing (in Chinese)*, 20(5): 875-898 (梁顺林, 程洁, 贾坤, 江波, 刘强, 刘素红, 肖志强, 谢先红, 姚云军, 袁文平, 张晓通, 赵祥. 2016. 陆表定量遥感反演方法的发展新动态. *遥感学报*, 20(5): 875-898) [DOI: 10.11834/jrs.20166258]
- Liu L Y. 2014. *Principles and Applications of Quantitative Remote Sensing of Vegetation*. Beijing: Science Press (刘良云. 2014. 植被定量遥感原理与应用. 北京: 科学出版社)
- Liu M J, Tang W J, Zhao R M, Liu G H, Liu Y, Li M Z and Sun H. 2024. Improving detection of wheat canopy chlorophyll content based on inhomogeneous light correction. *Computers and Electronics in Agriculture*, 226: 109361 [DOI: 10.1016/j.compag.2024.109361]
- Liu Y B, Pei J, Zou Y P, Tan S F, He Y N, Zheng X P, Wang T X, Fang H J, Wang L and Huang J X. 2025. A novel hybrid-DCNN-based framework for enhanced rice aboveground biomass estimation under limited samples. *IEEE Transactions on Geoscience and Remote Sensing*, 63: 4405716 [DOI: 10.1109/tgrs.2025.3544343]
- Ma H and Liang S L. 2022. Development of the GLASS 250-m leaf area index product (version 6) from MODIS data using the bidirectional LSTM deep learning model. *Remote Sensing of Environment*, 273: 112985 [DOI: 10.1016/j.rse.2022.112985]
- Mercier A, Betbeder J, Baudry J, Le Roux V, Spicher F, Lacoux J, Roger D and Hubert-Moy L. 2020. Evaluation of Sentinel-1 and 2 time series for predicting wheat and rapeseed phenological stages. *ISPRS Journal of Photogrammetry and Remote Sensing*, 163: 231-256 [DOI: 10.1016/j.isprsjprs.2020.03.009]
- Myneni R B, Hoffman S, Knyazikhin Y, Privette J L, Glassy J, Tian Y, Wang Y, Song X, Zhang Y, Smith G R, Lotsch A, Friedl M, Morisette J T, Votava P, Nemani R R and Running S W. 2002. Global products of vegetation leaf area and fraction absorbed PAR from year one of MODIS data. *Remote Sensing of Environment*, 83(1/2): 214-231 [DOI: 10.1016/S0034-4257(02)00074-3]
- Pan H Z, Chen Z X, Ren J Q, Li H and Wu S R. 2019. Modeling winter wheat leaf area index and canopy water content with three different approaches using Sentinel-2 multispectral instrument data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(2): 482-492 [DOI: 10.1109/JSTARS.2018.2855564]
- Pu R L, Gong P, Biging G S and Larrieu M R. 2003. Extraction of red edge optical parameters from Hyperion data for estimation of forest leaf area index. *IEEE Transactions on Geoscience and Remote Sensing*, 41(4): 916-921 [DOI: 10.1109/TGRS.2003.813555]
- Punalekar S M, Verhoef A, Quaife T L, Humphries D, Bermingham L and Reynolds C K. 2018. Application of Sentinel-2A data for pasture biomass monitoring using a physically based radiative transfer model. *Remote Sensing of Environment*, 218: 207-220 [DOI: 10.1016/j.rse.2018.09.028]
- Qi J B, Xie D H, Yin T G, Yan G J, Gastellu-Etcheberry J P, Li L Y, Zhang W M, Mu X H and Norford L K. 2019. LESS: large-scale remote sensing data and image simulation framework over heterogeneous 3D scenes. *Remote Sensing of Environment*, 221: 695-706 [DOI: 10.1016/j.rse.2018.11.036]
- Qiao K, Zhu W Q, Xie Z Y, Wu S N and Li S D. 2024. New three red-edge vegetation index (VI3RE) for crop seasonal LAI prediction using Sentinel-2 data. *International Journal of Applied Earth Observation and Geoinformation*, 130: 103894 [DOI: 10.1016/j.jag.2024.103894]
- Qu Y H, Zhang Y Z and Xue H Z. 2014. Retrieval of 30-m-resolution leaf area index from China HJ-1 CCD data and MODIS products through a dynamic Bayesian network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1): 222-228 [DOI: 10.1109/JSTARS.2013.2259472]
- Saltelli A, Ratto M, Tarantola S and Campolongo F. 2006. Sensitivity analysis practices: strategies for model-based inference. *Reliability Engineering and System Safety*, 91(10/11): 1109-1125 [DOI: 10.1016/j.res.2005.11.014]
- Suits G. 1971. The calculation of the directional reflectance of a vegetative canopy. *Remote Sensing of Environment*, 2: 117-125 [DOI: 10.1016/0034-4257(71)90085-X]
- Sun H L, Yu G R, Ouyang Z, Su Y R and Fu W. 2012. *China Ecosystem Positioning Observation and Research Dataset - Farmland Ecosystem Volume-Huanjian Station, Guangxi 2005-2009*. Beijing: China Agricultural Press (孙鸿烈, 于贵瑞, 欧阳竹, 苏以荣, 傅伟. 2012. 中国生态系统定位观测与研究数据集-农田生态系统卷-广西环江站 2005-2009. 北京: 中国农业出版社)
- Sun Y H, Qin Q M, Ren H Z and Zhang Y. 2022. Decameter cropland LAI/FPAR estimation from Sentinel-2 imagery using Google Earth Engine. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 4400614 [DOI: 10.1109/TGRS.2021.3052254]
- Tang Y J and Wang Q M. 2025. Spatial reconstruction-aided spatiotemporal fusion of NDVI images. *National Remote Sensing Bulletin*, 29(8): 2602-2615 (唐以洁, 王群明. 2025. 耦合空域重建的植被指数时空融合方法. *遥感学报*, 29(8): 2602-2615) [DOI: 10.11834/jrs.20254449]
- Tillack A, Clasen A, Kleinschmit B and Förster M. 2014. Estimation of the seasonal leaf area index in an alluvial forest using high-resolution satellite-based vegetation indices. *Remote Sensing of Environment*, 141: 52-63 [DOI: 10.1016/j.rse.2013.10.018]

- Verger A, Vigneau N, Chéron C, Gilliot J M, Comar A and Baret F. 2014. Green area index from an unmanned aerial system over wheat and rapeseed crops. *Remote Sensing of Environment*, 152: 654-664 [DOI: 10.1016/j.rse.2014.06.006]
- Verhoef W. 1984. Light scattering by leaf layers with application to canopy reflectance modeling: the SAIL model. *Remote Sensing of Environment*, 16(2): 125-141 [DOI: 10.1016/0034-4257(84)90057-9]
- Verrelst J, Camps-Valls G, Muñoz-Mari J, Rivera J P, Veroustraete F, Clevers J G P W and Moreno J. 2015. Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties – A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 108: 273-290 [DOI: 10.1016/j.isprsjprs.2015.05.005]
- Viña A, Gitelson A A, Nguy-Robertson A L and Peng Y. 2011. Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12): 3468-3478 [DOI: 10.1016/j.rse.2011.08.010]
- Wan L, Ryu Y, Dechant B, Lee J, Zhong Z L and Feng H Z. 2024. Improving retrieval of leaf chlorophyll content from Sentinel-2 and Landsat-7/8 imagery by correcting for canopy structural effects. *Remote Sensing of Environment*, 304: 114048 [DOI: 10.1016/j.rse.2024.114048]
- Wang D T and Qu Y H. 2024. Time-series accuracy validation and variation characteristic analysis of MODIS leaf-area index products for crop in the middle reaches of the Heihe River. *National Remote Sensing Bulletin*, 28(2): 359-374 (王丹彤, 屈永华. 2024. 黑河中游农作物MODIS叶面积指数产品时间序列精度验证与变化特征分析. *遥感学报*, 28(2): 359-374) [DOI: 10.11834/jrs.20221216]
- Wang J W, Lopez-Lozano R, Weiss M, Buis S, Li W J, Liu S Y, Baret F and Zhang J H. 2022. Crop specific inversion of PROSAIL to retrieve green area index (GAI) from several decametric satellites using a Bayesian framework. *Remote Sensing of Environment*, 278: 113085 [DOI: 10.1016/j.rse.2022.113085]
- Wang N, Tian J and Tian Q J. 2024. A method for reconstructing long-term daily resolution EVIs based on MODIS daily surface reflectance products. *National Remote Sensing Bulletin*, 28(4): 969-980 (王宁, 田家, 田庆久. 2024. 基于MODIS日地表反射率产品的长时序日分辨率EVI重建方法. *遥感学报*, 28(4): 969-980) [DOI: 10.11834/jrs.20243141]
- Wang Y Q, Gu Y Y, Tang J X, Guo B B, Warner T A, Guo C L, Zheng H B, Hosoi F, Cheng T, Zhu Y, Cao W X and Yao X. 2024. Quantify wheat canopy leaf angle distribution using terrestrial laser scanning data. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 4402815 [DOI: 10.1109/TGRS.2024.3353225]
- Wu D X, Wei W S and Zhang S M. 2007. *Protocols for Standard Biological Observation and Measurement in Terrestrial Ecosystems*. Beijing: China Environmental Science Press (吴冬秀, 韦文珊, 张淑敏. 2007. *陆地生态系统生物观测规范*. 北京: 中国环境科学出版社)
- Wu T Z, Zhang Z W, Wang Q, Jin W J, Meng K, Wang C, Yin G F, Xu B D and Shi Z H. 2024. Estimating rice leaf area index at multiple growth stages with Sentinel-2 data: an evaluation of different retrieval algorithms. *European Journal of Agronomy*, 161: 127362 [DOI: 10.1016/j.eja.2024.127362]
- Xing M Q, Wang W, Fang X and Xue H W. 2022. Rice OsIAA6 interacts with OsARF1 and regulates leaf inclination. *The Crop Journal*, 10(6): 1580-1588 [DOI: 10.1016/j.cj.2022.02.010]
- Xu B D, Li J, Liu Q H, Zeng Y L, Yin G F, Zhao J and Yang L. 2015. Spatial representativeness estimation of station observation in validation of LAI products: a case study with CERN in-situ data. *Journal of Remote Sensing (in Chinese)*, 19(6): 910-927 (徐保东, 李静, 柳钦火, 曾也鲁, 尹高飞, 赵静, 杨乐. 2015. 地面站点叶面积指数观测的空间代表性评价——以CERN站网观测为例. *遥感学报*, 19(6): 910-927) [DOI: 10.11834/jrs.20154246]
- Yang M H, Wu Q, Qi J B, Yang G J, Wang Z P, Wang Z Y, Zhang J, Yang H, Cheng J P, Xiong S P and Ma X M. 2025a. A robust two-stage framework for maize above-ground biomass prediction integrating spectral remote sensing and allometric growth model. *Computers and Electronics in Agriculture*, 235: 110398 [DOI: 10.1016/j.compag.2025.110398]
- Yang Q, Zhou J X, Zhao L Y and Jin Z N. 2025b. NeRF-LAI: a hybrid method combining neural radiance field and gap-fraction theory for deriving effective leaf area index of corn and soybean using multi-angle UAV images. *Remote Sensing of Environment*, 328: 114844 [DOI: 10.1016/j.rse.2025.114844]
- Zarco-Tejada P J, Hornero A, Beck P S A, Kattenborn T, Kempeneers P and Hernández-Clemente R. 2019. Chlorophyll content estimation in an open-canopy conifer forest with Sentinel-2A and hyperspectral imagery in the context of forest decline. *Remote Sensing of Environment*, 223: 320-335 [DOI: 10.1016/j.rse.2019.01.031]
- Zérah Y, Valero S and Inglada J. 2024. Physics-constrained deep learning for biophysical parameter retrieval from Sentinel-2 images: inversion of the PROSAIL model. *Remote Sensing of Environment*, 312: 114309 [DOI: 10.1016/j.rse.2024.114309]
- Zhang H, Li J, Liu Q H, Zhang Z X, Zhu X R, Liu C, Zhao J, Dong Y D, Xu B D and Meng J H. 2023. GF-1 leaf area index product across China based on three-dimensional stochastic radiation transfer model. *National Remote Sensing Bulletin*, 27(3): 677-688 (张虎, 李静, 柳钦火, 张召星, 朱欣然, 刘畅, 赵静, 董亚冬, 徐保东, 蒙继华. 2023. 基于三维随机辐射传输模型的高分一号中国叶面积指数产品算法. *遥感学报*, 27(3): 677-688) [DOI: 10.11834/jrs.20231708]
- Zhang W J, Yang G J, Qi J B, Chen R Q, Zhang C J, Xu B, Wu B G, Su X H and Zhao C J. 2025. The impacts of tree shape, disease distribution and observation geometry on the performances of disease spectral indices of apple trees. *Remote Sensing of Environment*, 329: 114953 [DOI: 10.1016/j.rse.2025.114953]
- Zhang Y Y, He X Q, Lian G, Bai Y, Yang Y, Gong F, Wang D F, Zhang Z L, Li T and Jin X C. 2023. Monitoring and spatial traceability of river water quality using Sentinel-2 satellite images. *Science of the Total Environment*, 894: 164862 [DOI: 10.1016/j.scitotenv.2023.164862]
- Zhen Z J, Chen S B, Yin T G and Gastellu-Etchegorry J P. 2023. Globally quantitative analysis of the impact of atmosphere and spectral

response function on 2-band enhanced vegetation index (EVI2)
over Sentinel-2 and Landsat-8. ISPRS Journal of Photogrammetry

and Remote Sensing, 205: 206-226 [DOI: 10.1016/j.isprsjprs.
2023.09.024]

Retrieval of crop leaf area index by coupling red-edge band features

XU Baodong¹, SONG Zhubeijia¹, WU Tongzhou¹, MENG Ke¹, WANG Qi¹, WEI Haodong², YIN Gaofei³

1. Huazhong Agricultural University, College of Resources and Environment, Digital Agriculture Research Institute,
Wuhan 430070, China;

2. Huazhong Agricultural University, Plant Science and Technology, Wuhan 430070, China;

3. Southwest Jiaotong University, Faculty of Geosciences and Environmental Engineering, Chengdu 610031, China

Abstract: Leaf Area Index (LAI) is a key biophysical parameter that characterizes the canopy structure and growth status of crops. The accurate and timely monitoring of LAI by using remote sensing technology is crucial for field water and fertilizer management, food security assurance, and the assessment of agricultural production potential. As a spectrally sensitive band that indicates leaf physiology and canopy structural changes, the red-edge region has been introduced into multiple medium- to high-resolution (10–30 m) satellite sensors and widely applied to crop parameter estimation, providing opportunities to improve further the accuracy of LAI retrieval. However, existing studies have demonstrated considerable differences in the application of red-edge bands for LAI inversion, and the effective means to leverage red-edge information for improving LAI retrieval remains unclear due to variations in study regions. To address this issue, this study proposed a hybrid method for crop LAI retrieval by integrating the PROSAIL model with Machine Learning (ML) algorithms.

This study developed a hybrid LAI retrieval framework by coupling the PROSAIL model with ML algorithms, using Sentinel-2 multispectral imagery and in-situ LAI measurements of major cereal crops (rice, wheat, and maize) provided by the Chinese National Ecosystem Research Network. First, the PROSAIL model was used to generate LAI-canopy reflectance simulation dataset, and sensitivity analysis of the model parameters was conducted to clarify their contributions to the reflectance of different bands. Then, five ML algorithms, namely, multilayer perceptron regression (MLPR), support vector regression (SVR), Gaussian process regression (GPR), random forest regression (RFR), and gradient boosting decision tree (GBDT), were used to develop hybrid inversion models based on the generated simulation dataset, and the optimal ML algorithm was selected based on the validation dataset. Subsequently, the performance of the retrieval models that use eight band combinations was evaluated to identify the optimal combination that incorporated red-edge bands. Finally, on the basis of the optimization of the ML algorithm and band combination, we further evaluated the accuracy and applicability of the proposed method under different scenarios.

Results demonstrated that the integration of red-edge bands effectively improved LAI retrieval performance, with the joint utilization of Red-Edge 1 (RE1) and Red-Edge 3 (RE3) contributing most significantly. MLPR performed the best in the validation and testing datasets, highlighting its capability to capture the nonlinear relationship between canopy reflectance and LAI. Compared with the Z1 combination (Green+Red+NIR+SWIR1+SWIR2) without red-edge bands, the Z7 combination (Green+Red+NIR+SWIR1+SWIR2+RE1+RE3) achieved the highest inversion accuracy ($R^2=0.784$, RMSE=0.826), with R^2 increasing by 4.9% and RMSE decreasing by 15.6%. Further analysis indicated that the appropriate incorporation of the red-edge bands not only reduced systematic bias in LAI estimation but also effectively mitigated the saturation effect in the medium to high LAI range ($4 < \text{LAI} < 5$), with |Bias| and RMSE decreasing by 52.2% and 41.4%, respectively. In addition, different crops showed varied responses to red-edge information, with the most significant improvement in maize (R^2 increased by 17.9% and RMSE decreased by 29.1%), followed by wheat and then rice. These differences may be attributed to variations in canopy structure and leaf distribution among crop types.

Overall, the combination of the optimal ML algorithm and red-edge bands can significantly improve the accuracy and robustness of crop LAI inversion. This study provides methodological support and practical guidance for fully utilizing red-edge information in the large-scale and long-term precise monitoring of crop growth.

Key words: crop leaf area index, red-edge bands, PROSAIL model, machine learning, band selection

Supported by National Natural Science Foundation of China (No. 42271360, 42001303)