

doi:10.6041/j.issn.1000-1298.2023.05.018

# 基于无人机多源遥感的玉米 LAI 垂直分布估算

刘帅兵<sup>1</sup> 金秀良<sup>2,3</sup> 冯海宽<sup>4</sup> 聂臣巍<sup>2,3</sup> 白 怡<sup>2</sup> 余 汛<sup>2,3</sup>(1. 武汉大学遥感信息工程学院, 武汉 430079; 2. 中国农业科学院作物科学研究所, 北京 100081;  
3. 中国农业科学院国家南繁研究院, 三亚 572024; 4. 北京市农林科学院信息技术研究中心, 北京 100097)

**摘要:** 为探究无人机多源遥感影像估算玉米叶面积指数(Leaf area index, LAI)垂直分布, 在田间设置了密度和播期试验, 在7个生育时期利用无人机采集了可见光、多光谱和热红外影像并同步获取玉米LAI垂直分布数据。同时, 为合理制定无人机飞行任务, 分析了不同飞行高度和不同太阳高度角下获取的无人机影像对估算玉米LAI的影响。基于无人机影像提取的与玉米LAI相关性较高的植被指数、纹理信息和冠层温度等特征, 利用7种机器学习方法分别构建了玉米冠层不同高度LAI估算模型, 从中选取鲁棒性强的2个模型用于分析在不同飞行高度和不同太阳高度角下估算LAI的差异。研究结果表明, MLP-RFR和RFR模型对玉米LAI估算鲁棒性最强, 全生育期下模型rRMSE分别为11.31% (MLP-RFR) 和11.42% (RFR)。玉米冠层LAI垂直分布估算误差, 所有模型的平均rRMSE分别为9.1% (LAI-1)、14.19% (LAI-2)、18.62% (LAI-3)、23.29% (LAI-4) 和26.7% (LAI-5)。对于玉米穗位叶及以下部位的LAI估算误差均在20%以下, 得到了较好精度。同时, 在不同飞行高度和太阳高度角试验中可以得出, 当飞行高度为30 m时LAI估算精度最高,  $R^2$ 为0.73, rRMSE为10.97%, 在09:00—10:00观测的玉米LAI估算精度最高。无人机多源遥感影像数据可以准确估算玉米冠层LAI垂直分布, 及时掌握玉米功能叶片LAI长势差异, 可为玉米品种筛选提供辅助。

**关键词:** 玉米; 叶面积指数; 无人机多源遥感; 垂直分布; 飞行试验

中图分类号: TP75 文献标识码: A 文章编号: 1000-1298(2023)05-0181-13

OSID:



## Vertical Distribution Estimation of Maize LAI Using UAV Multi-source Remote Sensing

LIU Shuaibing<sup>1</sup> JIN Xiuliang<sup>2,3</sup> FENG Haikuan<sup>4</sup> NIE Chenwei<sup>2,3</sup> BAI Yi<sup>2</sup> YU Xun<sup>2,3</sup>

(1. School of Remote Sensing and Information Engineering, Wuhan University, Wuhan 430079, China

2. Institute of Crop Science, Chinese Academy of Agricultural Sciences, Beijing 100081, China

3. National Nanfan Research Institute (Sanya), Chinese Academy of Agricultural Sciences, Sanya 572024, China

4. Information Technology Research Center, Beijing Academy of Agriculture and Forest Sciences, Beijing 100097, China

**Abstract:** Maize leaf area index (LAI) displays a significant vertical distribution gradient. However, there is currently a limited amount of research focused on directly estimating the vertical distribution patterns of maize LAI from images. Designing an appropriate unmanned aerial vehicle (UAV) detection scheme can contribute to improving the accuracy of maize LAI estimation. Thus different maize varieties, and density and disease were used, and sowing experiments were carried out in the field to collect data on the vertical distribution of maize LAI. UAVs equipped with RGB, multi-spectral (MS), and thermal infrared (TIR) cameras were used to capture visible, multi-spectral, and thermal infrared images. Seven sets of UAV image data were collected during the reproductive growth stage of maize. To validate the effects of different UAV flight altitudes and solar zenith angles on maize LAI estimation, two completely controlled experiments with different flight altitudes were conducted, resulting in a total of 10 sets of UAV image data. Additionally, UAV image data were collected at each hour from 08:00 to 18:00 on a single day, resulting in 11 sets of image data, to discuss the robustness of the maize LAI estimation model under different flight experiments. A multi-source remote sensing image dataset was constructed to provide

收稿日期: 2023-02-24 修回日期: 2023-03-26

基金项目: 国家重点研发计划项目(2016YFD0300602)、国家自然科学基金项目(42071426, 51922072, 51779161, 51009101)、海南省崖州湾种子实验室项目(JBGS+B21HJ0221)和中国农业科学院南繁研究院南繁专项(YJTCY01, YBXM01)

作者简介: 刘帅兵(1994—), 男, 研究实习员, 博士, 主要从事作物表型和农业定量遥感研究, E-mail: liushuaibing@whu.edu.cn

image feature variables highly correlated with maize LAI. Eight texture information categories were generated based on gray-level co-occurrence matrix from the original image texture features. In the end, 51, 43, and 9 image features were obtained from RGB, MS, and TIR image data sources, respectively. Seven machine learning models, including GBDT, LightGBM, MLP, PLSR, RFR, SVR, and XGBoost, were selected to estimate the vertical distribution of maize LAI. These models were applied to estimate LAI vertical distribution data at different maize growth stages. Two models with the strongest robustness were selected to verify the optimal observation time and flight altitude under different drone flight heights and sun elevation angles. The research results showed that during the reproductive growth stage of maize, the best single growth period for estimating maize LAI was the tasseling period. The MLP model had  $R^2$  of 0.91 and rRMSE of 5.1% for LAI estimation. At the same time, the LAI estimation accuracy obtained during the maize maturation period was the worst, with  $R^2$  of 0.8 and rRMSE of 11.01%. As the measurement height of maize LAI was increased, the accuracy trend differed from that at the bottom, showing a trend of first decreasing and then increasing. Based on the experiments conducted involving different flight and solar altitude angles, it was concluded that lower flight altitudes of UAVs led to higher accuracy in estimating maize LAI. Specifically, at a flight altitude of 30 m, the MLP model achieved an accuracy of  $R^2$  of 0.73 and RMSE of 10.97%. Additionally, the highest accuracy in maize LAI observation was achieved when observations were conducted at 09:00 and 10:00 in the morning. The use of UAV remote sensing technology, combined with multi-source image data, enabled accurate observation of the vertical distribution of LAI in maize canopies. This approach enabled a precise understanding of the spatial distribution of maize LAI at different heights, and provided timely information on the health status of functional leaves. The acquired data can be used to adjust field management measures accordingly. Furthermore, experts in maize breeding can use this technology to identify differences between maize varieties and select specific cultivars, which had significant practical implications.

**Key words:** maize; leaf area index; UAV multi-source remote sensing; vertical distribution; flight test

## 0 引言

LAI是玉米表型参数的重要组成部分,是评价作物长势、预测产量、选育优良品种的重要参数<sup>[1]</sup>。LAI高的植物往往具有更快的光合活性速率和生长速率,从而提升作物产量,因此,选择LAI高的品种对于育种工程具有重要意义<sup>[2]</sup>。目前,随着中国育种工程不断发展,大多数玉米基因型已经测序完毕,急需可以大范围观测精细作物冠层结构的方法<sup>[3]</sup>。因此,观测玉米育种材料间的性状差异,可以为育种专家提供大量、稳定可靠的田间表型数据,有利于挑选高抗、性状稳定和高产的优良品种<sup>[4-5]</sup>。玉米LAI田间观测分为直接观测和间接观测两种<sup>[6]</sup>。直接观测是采用破坏性取样的方式,在田间获取整株玉米叶片,经过测量叶片面积从而计算玉米LAI<sup>[7]</sup>。而间接观测法主要是利用光学传感器或通过测量辐射透过率来计算玉米LAI<sup>[8-9]</sup>。但这两种方式皆为人工观测,费时费力,面对规模化的育种试验而言具有工作量大、效率低、主观性强等缺点<sup>[10]</sup>。无人机(Unmanned aerial vehicle, UAV)凭借其高通量、灵活方便、快速无损等特点,逐渐成为农业育种领域主要的遥感监测平台<sup>[11]</sup>。无人机遥感平台可以搭载各种光学传感器,满足田间作物长势监测需求,快速准确获取玉米LAI信息<sup>[12]</sup>。

玉米冠层LAI呈现明显的垂直分布梯度,但目前很少有研究针对玉米LAI垂直分布规律,从影像中直接估算,缺乏系统性分析<sup>[13]</sup>。冠层中太阳辐射分布除了受其自身变化影响外,还受到叶片方位角,叶片尺寸,叶片形状和叶片的吸收、散射和反射等影响。通过分析玉米LAI在冠层不同高度的分布,可以有效对玉米功能叶长势进行监测<sup>[8]</sup>,为玉米最终估产提供重要的数据支撑,因此有必要进一步系统地研究估算玉米LAI垂直分布。目前,针对玉米LAI垂直分布监测的方式主要有两大类:①基于统计模型的遥感估算方法,通过高空或地面遥感光谱反射率数据,建立植被指数(多个原始波段的组合)与玉米LAI之间的统计关系,从而实现对LAI的定量估算<sup>[14-15]</sup>。②基于遥感物理机理模型,该方法中模型参数需要有明确的参数输入,构建非线性模型,方程复杂,实用性差,运算量会随着模型参数的增加呈现几何倍数的增长<sup>[16]</sup>。同时,针对模型优化的方法缺乏统一标准,当遇到代价函数和迭代策略不合适时,模型估算结果很难收敛。植被指数法简单实用,具有很强的普适性,在作物长势参量垂直分布估算中得到了广泛关注<sup>[17-18]</sup>。

无人机遥感可以根据不同实际需求,方便灵活地制定飞行任务。但相较于其他高空遥感平台,无人机短时间内可监测面积受飞行高度影响较大,而

不同飞行高度获取的影像空间分辨率不同,进而对LAI估算产生影响,需进一步探究不同飞行高度下获取的数据对玉米LAI估算的影响。太阳高度角在一天中是动态变化的,在不同的时间段,玉米阴影投影面积也不一样,剔除土壤像素时,阴面叶片像素往往也容易被错误剔除。因此,探索田间不同无人机飞行任务对LAI精确估算的影响,有助于制定合理的田间飞行任务试验,为田间玉米LAI精准监测提供技术支持。

综上,本文以新乡市玉米育种材料为研究对象,搜集田间玉米LAI垂直分布数据,采用无人机搭载数码相机、多光谱相机和热红外相机,构建多种植被指数并提取冠层温度信息,作为影像特征变量。利用梯度提升树(Gradient-boosting decision tree, GBDT)<sup>[19]</sup>、轻量级梯度提升树(Light gradient boosting machine, LightGBM)<sup>[20]</sup>、多层次感知机回归(Multilayer perceptron regression, MLP)、偏最小二

乘回归(Partial least-square regression, PLSR)<sup>[21]</sup>、随机森林回归模型(Random forest regression, RFR)<sup>[22]</sup>、支持向量机回归(Support vector machine regression, SVR)<sup>[23]</sup>和极端提升树(Extreme gradient boosting, XGBoost)7个机器学习方法分别构建LAI垂直分布估算模型,同时探讨无人机在不同飞行高度以及不同太阳高度角下获取的数据对LAI估算的影响,以期为田间玉米LAI准确估算提供技术支持。

## 1 材料与方法

### 1.1 试验设计

2022年玉米田间试验设置在河南省新乡市新乡县七里营镇中国农业科学院新乡综合试验基地(图1)。试验区地处暖温带大陆性季风气候( $113^{\circ}45'55''E, 35^{\circ}08'28''N$ ),四季分明,年平均气温 $14^{\circ}C$ ,其中7月最热,平均气温 $27.3^{\circ}C$ ,年均相对湿度68%,平均降水量为656.3 mm,年蒸发量为1748.4 mm。

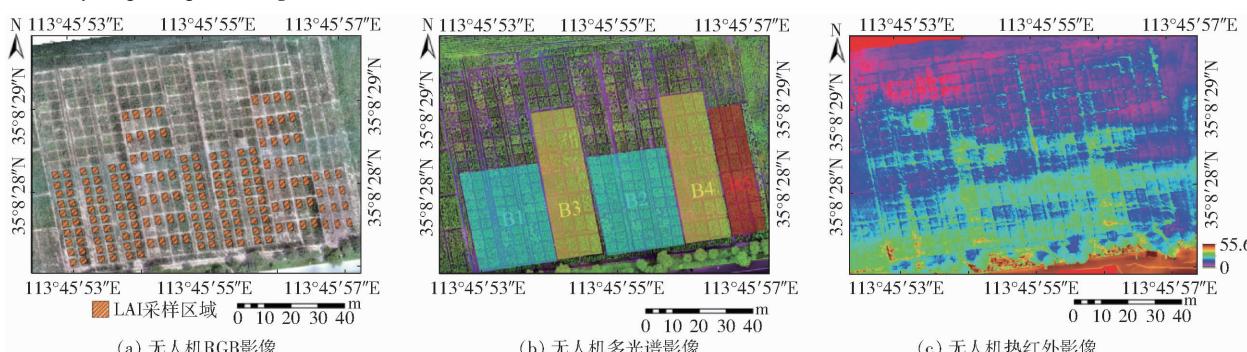


图1 2022年玉米田间种植试验设计

Fig. 1 Design of maize field planting experiment in 2022

在播种前田间施加基肥,包括硫酸钾( $K_2SO_4$ , 52%,  $12\text{ kg}/\text{hm}^2$ )、尿素(N, 46%,  $200\text{ kg}/\text{hm}^2$ )以及过磷酸钙( $Ca(H_2PO_4)_2$ , 12%,  $90\text{ kg}/\text{hm}^2$ )。试验区玉米的播种方式为行播种,灌溉方式为大水漫灌,播种时间为2022年6月7日。

无人机及玉米LAI垂直分布观测试验于2022年7—9月进行。试验区设置3个不同的玉米试验设计,即玉米病害试验、玉米种植密度试验和玉米播期试验。整个试验区东西总长112.5 m,南北总长82 m(包括保护行),株间距设置为22.5 cm,种植行间距设置为60 cm,播种深度为5 cm。所有玉米小区均在2022年6月7日种植完毕。

(1)玉米病害试验(试验1):试验区设置20个自交系和20个杂交系共40种玉米品种。接种试验选择的病种类型为玉米小斑病和玉米弯孢病。田间设置了3个对照试验,每种病害都接种1个对照中全部40个玉米品种,剩下1个为健康对照组。在田间设置了完全对照重复试验,以避免产生偶然误差。

(图1b中B1、B2)。每个玉米小区尺寸设置为 $3\text{ m} \times 3\text{ m}$ ,小区南北和东西方向分别设置了0.7 m和1.2 m的过道。每个病害对照试验之间设置了2个1 m过道以及3行(1.6 m)抗病性较强的玉米品种,避免各玉米小区之间的交叉感染。试验选取一半玉米病害小区作为LAI观测区域。

(2)玉米密度试验(试验2):试验区设置7个杂交系玉米品种,4个不同的种植密度,共计28个玉米小区。密度分别设置为 $15\,000\text{ 株}/\text{hm}^2$ (1K)、 $45\,000\text{ 株}/\text{hm}^2$ (3K)、 $75\,000\text{ 株}/\text{hm}^2$ (5K)和 $105\,000\text{ 株}/\text{hm}^2$ (7K)。同样在田间设置了完全对照试验(图1b中B3、B4)。密度小区南北长7 m,东西长3 m,南北和东西方向分别设置0.7 m和1.2 m的过道。其中小区南半部分为破坏性取样区域,因此本研究玉米LAI观测主要集中在小区北面。

(3)玉米播期试验(试验3):试验区区别于试验1、2,将玉米播种时间延后21 d,即2022年6月28日播种。设置4个玉米杂交品种,3个重复共12

个小区。玉米小区南北长 5.4 m, 宽 3 m, 小区南北和东西方向分别设置 0.8 m 和 1.2 m 的过道, 具体空间分布如图 1b 中 B5 所示。

## 1.2 LAI 数据和无人机多源遥感影像采集

玉米垂直分布试验采用 Sunscan 冠层分析仪进行观测, 具体如图 2 所示。

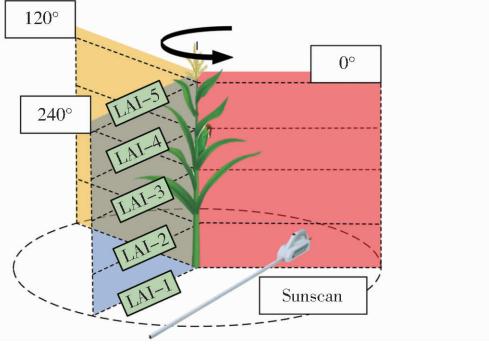


图 2 玉米 LAI 垂直分布田间观测设计

Fig. 2 Field observation design of vertical distribution of maize LAI

当试验进入玉米抽雄期, 此时玉米整体生理结构定型、株高稳定、生殖器官发育完备, 具备了在固定高度对 LAI 垂直分布数据进行测量的田间条件。因此 LAI 垂直分布设置在玉米抽雄期进行测量, 在竖直方向上分为 5 层对 LAI 进行观测。第 1 层贴近地面, 第 2 层为穗位叶与地面之间 1/2 处, 第 3 层为玉米穗位叶高度, 第 4 层为穗位叶与顶部叶片 1/2 处, 第 5 层位于顶层叶片处。每层 LAI 分别在 0°、120°、240° 3 个方向观测, 取平均值作为每层 LAI 的观测数据。选择在避免太阳光直射的条件下, 测量玉米垂直分布数据。玉米 LAI 垂直分布如图 3 所示(以 9 月 15 日玉米成熟期为例)。由于当地气候不适以及极端灾害导致玉米倒伏的影响, 虽然对田间倒伏玉米进行了架设竹竿等补救措施, 但玉米倒伏现象仍导致玉米 LAI 观测值整体偏低。

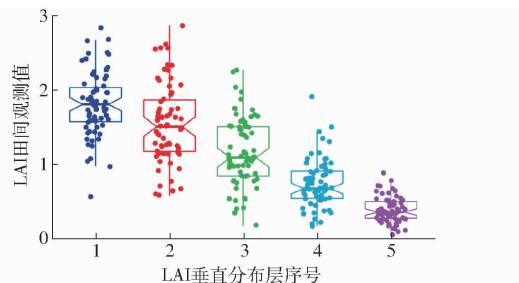


图 3 玉米 LAI 垂直分布(以 9 月 15 日为例)

Fig. 3 Vertical distribution of maize LAI (taking September 15 as an example)

无人机采用 DJI Matrice M300 型和 DJI Matrice M600 Pro 型两款电动旋翼无人机(深圳大疆创新科技有限公司)。玉米不同生育期试验采用的是 DJI M600 Pro 型六旋翼电动无人机 + DJI Romin - MX 型

摄影云台搭载 SONY ILCE - 7M2 型数码相机(Sony Corporation, 日本)获取高精度的 RGB 影像。采用 DJI M300 四旋翼电动无人机搭载 Micasense RedEdge - MX 型多光谱相机(Micasense, Inc., 美国)和 FLIR DUO PRO R 640 型热红外相机(FLIR Systems, Inc., 美国), 分别获取多光谱(MS)和热红外(TIR)无人机遥感影像。无人机及传感器具体如图 4 所示。

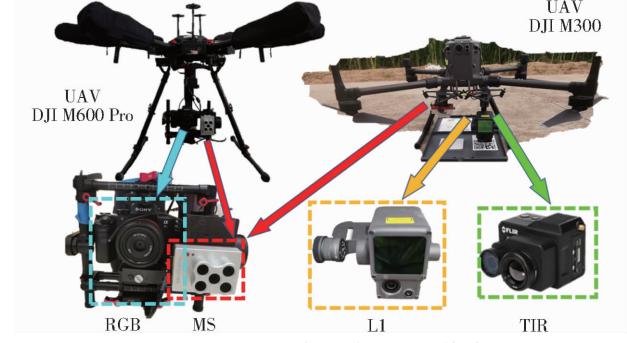


图 4 无人机平台及其搭载的传感器

Fig. 4 UAV remote sensing platform and its equipped sensors

在进行不同飞行高度和不同太阳高度角的影像数据获取时, 由于飞行任务频繁, 为了避免影响整体试验进程, 采用 DJI M300 型无人机搭载禅思 L1 型传感器(RGB 镜头)和 Micasense RedEdge - MX 型多光谱相机, 获取 RGB 影像和 MS 影像(未获取 TIR 影像)。具体飞行任务设置、影像细节和太阳高度角方位角信息如表 1 所示。

2022 年 8 月 3 日—9 月 15 日, 在玉米的不同生育期进行数据采集, 飞行高度设置为 30 m, 飞行速度设置为 2 m/s, 影像航向和旁向重叠率设置为 85%。2022 年 9 月 17 日, 开展无人机飞行高度试验, 分别设置 30、50、70、90、120 m 5 个飞行高度, 飞行速度设置为 2 m/s; 飞行试验分别在上午和下午设置了完全对照试验, 共计 10 个飞行架次。2022 年 9 月 18 日设置不同太阳高度角和方位角的试验, 从 08:00—18:00, 每个整点飞行一个架次, 飞行高度设置为 30 m, 飞行速度设置为 2 m/s, 影像重叠率设置为 85%。玉米无人机搭载多源传感器所采集到的影像数据如图 1 所示。

统计了所有无人机数据采集时, 不同太阳高度角和方位角的信息(表 1)。无人机飞行前, 采集了无人机多光谱定标板和热红外地黑体温度定标板, 用于多光谱和热红外的辐射定标, 将多光谱和热红外的 DN 值转换成反射率和玉米冠层实际温度, 具体计算公式为

$$\rho_1 = \frac{D_1}{D_2} \rho_2 \quad (1)$$

$$f(x) = 0.035x - 233.59 \quad (2)$$

表 1 2022 年无人机飞行任务设置和影像太阳高度角、方位角信息

Tab. 1 2022 UAV flight parameter setting image and solar altitude azimuth information

试验类型	飞行日期	飞行高度/m	飞行次数	飞行器型号	影像分辨率(RGB, MS, TIR)/cm	太阳高度角/(°)	太阳方位角/(°)
玉米生育期试验	08-03(抽雄期)	30	1	M600	0.33, 2.21, 2.67	60.74	59.64
	08-10(吐丝期)	30	1	M600	0.34, 2.14, 2.57	47.10	-73.92
	08-17(籽粒建成期)	30	1	M600	0.33, 2.22, 2.64	62.48	42.33
	08-24(乳熟期)	30	1	M600	0.33, 2.11, 2.66	64.91	18.06
	08-31(蜡熟期)	30	1	M600	0.33, 2.01, 2.66	60.74	28.00
	09-08(凹陷期)	30	1	M600	0.33, 2.08, 2.65	40.10	-64.16
飞行高度试验	09-15(成熟期)	30	1	M600	0.32, 2.06, 2.63	50.23	41.69
		30	2		0.83, 2.06		
		50	2		1.38, 3.48		
	09-17	70	2	M300	1.92, 4.88	13.53 ~ 57.06	-85.7 ~ 18.45
		90	2		2.41, 6.28		
太阳高度角试验		120	2		3.28, 8.37		
	09-18	30	11	M300	0.83, 2.13	1.19 ~ 56.66	-91.37 ~ 73.81

$$T = f(D) \quad (3)$$

式中  $\rho_1, \rho_2$ ——无人机影像和多光谱辐射定标板反射率

$D_1, D_2$ ——无人机影像和多光谱辐射定标板辐亮度

$f(x)$ ——无人机热红外影像温度转换值

$x$ ——热红外的辐亮度

$T$ ——无人机影像玉米冠层温度

$D$ ——无人机影像玉米冠层辐亮度

由 Agisoft PhotoScan(Agisoft LLC, 俄罗斯)无人机影像处理软件对 RGB、MS 和 TIR 影像进行拼接和辐射校正操作, 最终获取 28 期无人机数据。

### 1.3 玉米叶面积指数反演模型构建

利用无人机多光谱影像的可见光波段构建了与叶片颜色相关的植被指数: INT<sup>[24]</sup>、GRVI<sup>[25]</sup>、NDI<sup>[26]</sup>、WI<sup>[27]</sup>、IKAW<sup>[28]</sup>、GLI<sup>[29]</sup>、GLI2<sup>[29]</sup>、VARI<sup>[30]</sup>、ExR<sup>[31]</sup>、ExG<sup>[31]</sup>、ExB<sup>[31]</sup>、ExGR<sup>[31]</sup>、VEG<sup>[32]</sup>、IPCA<sup>[33]</sup>、CIVE<sup>[33]</sup>、COM<sup>[34]</sup>、RGBVI<sup>[35]</sup>、MGRVI<sup>[36]</sup>, 并通过红边和近红外波段构建了与叶片光谱变化相关的植被指数: DVI<sup>[25]</sup>、EVI<sup>[37]</sup>、GNDVI<sup>[38]</sup>、VI<sub>(nir/green)</sub><sup>[39]</sup>、VI<sub>(nir/red)</sub><sup>[40]</sup>、VI<sub>(nir/rededge)</sub><sup>[40]</sup>、ln<sub>RE</sub><sup>[41]</sup>、MSAVI<sup>[42]</sup>、MSAVI2<sup>[42]</sup>、OSAVI<sup>[43]</sup>、MTVI2<sup>[44]</sup>、NDRE<sup>[45]</sup>、NDVI<sup>[46]</sup>、MSR<sup>[47]</sup>。同时, 从热红外影像中提取玉米冠层温度信息, 将玉米小区的温度平均值作为冠层温度信息。此外基于 RGB 影像的 3 个波段, MS 影像的红光、红边和近红外波段以及热红外影像分别计算了 8 种影像纹理特征, 包括均值 (Mean)、方差 (Variance)、均匀性 (Homogeneity)、对比度 (Contrast)、相异性 (Dissimilarity)、信息熵 (Entropy)、二阶矩 (Second moment) 和相关性 (Correlation)<sup>[22,48]</sup>。最终, 利用

RGB、MS 和 TIR 影像数据源分别得到了 51、43、9 种影像特征。本研究基于 LIU 等<sup>[49]</sup>的研究, 将所有多源遥感影像特征构建成 1 维多模态数据, 有效提高对玉米 LAI 估算效率。同时, 本文将根据提取的无人机影像特征变量与 LAI 的相关系数由高到低进行排序, 分析讨论了对玉米 LAI 估算较重要的特征变量, 每个生育时期按相关性排序选取前 10 个特征用于后续 LAI 反演分析。

本文选取 7 种机器学习模型以估算玉米 LAI 垂直分布数据, 分别是 GBDT、LightGBM、MLPR、PLSR、RFR、SVR 和 XGBoost 模型。在每个生育期都对玉米 LAI 进行了估算, 从模型中挑选最优的结果作为当前生育期 LAI 估算结果。同时, 利用在不同生育期内 LAI 估算结果最佳的 2 种方法基于在不同太阳高度角和不同飞行高度下获取的无人机影像分别构建 LAI 反演模型, 以评估最佳飞行高度和每日最佳观测玉米 LAI 的时间段, 为玉米大田种植条件下, 大范围检测 LAI 提供技术支撑。

为了在相同的标准下评估不同模型的性能, 将 2/3 的样本数据作为模型的训练集, 其余 1/3 的样本作为验证集。分别计算了分类模型和估测模型的决定系数 (Coefficient of determination,  $R^2$ )、均方根误差 (Root mean square error, RMSE)、相对均方根误差 (Relative root mean square error, rRMSE) 和平均绝对误差 (Mean absolute error, MAE), 用于评估模型的性能和准确性。

## 2 结果与评价

### 2.1 叶面积指数反演模型特征参数分析

无人机多源遥感影像数据所构建的所有影像特征与玉米 LAI 垂直分布数据的相关系数如图 5 所示

(以8月3日影像数据为例,其中后缀x的为RGB数据源,后缀y的为多光谱数据源)。结果显示,无人机影像特征变量中,RGB影像所构建的可见光植被指数和多光谱红光波段纹理特征与LAI相关性较好。多数影像特征与LAI的相关系数从玉米冠层顶部到底部依次升高。但有些影像特征呈现与之相反的趋势,可见光波段所构建的方差和对比度灰度共生矩阵影像特征与玉米LAI垂直分布的相关系数,从玉米冠层顶部到底部依次降低,这是以往研究所未能观测到的。

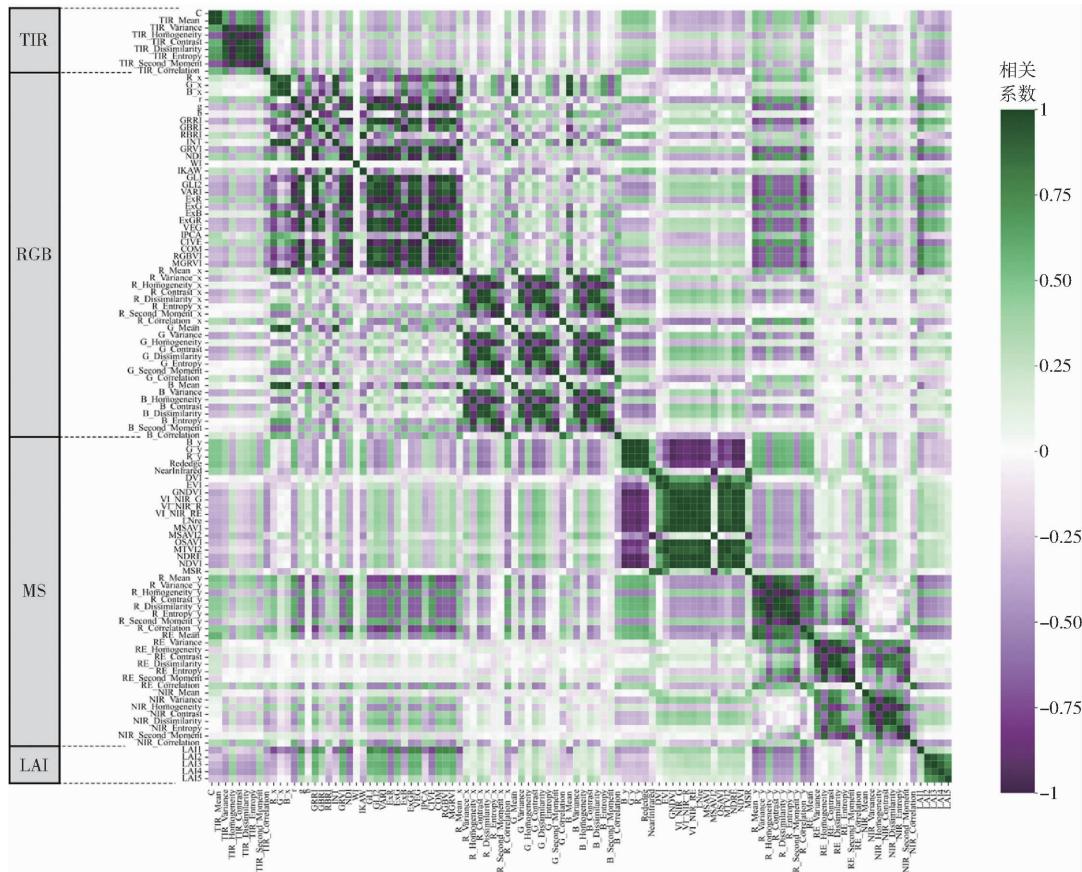


图5 无人机影像特征与玉米LAI的相关系数

Fig. 5 Correlation coefficient between UAV image features and maize LAI

在玉米不同生育时期,根据各特征参数与玉米冠层底部LAI相关性排序结果,每个生育时期选取前10个特征用于后续LAI反演分析,各生育时期特征选择结果如表2所示。结果显示,不同生育时期选择用于反演LAI的特征存在较大差异,整体上纹理特征在不同生育时期与LAI的相关性均比植被指数好。在玉米抽雄期至乳熟期,筛选的特征均为纹理特征,在腊熟期筛选的特征以植被指数为主,而在腊熟期之后筛选的特征既包含纹理特征也包含植被指数,但仍以纹理特征为主。此外,有个别特征参数在多数生育时期均与LAI存在较好的相关性,其中多光谱红光波段的均值纹理特征(R Mean)在玉米不同生育期内均与玉米LAI有很好相关性(除8月17日外),红边波段均值纹理信息(RE Mean)在4个玉米生育期(抽雄、吐丝、乳熟和凹陷期)内与LAI有良好的相关性,在玉米生长发育后期(8月31日、9月8日和9月15日),基于无人机RGB影像构建的VARI、GRVI和MGRVI植被指数均与玉米LAI

有较好的相关性。

## 2.2 不同生育时期玉米叶面积指数反演结果

不同生育期下玉米叶面积反演结果如表3所示(LAI-1估算结果)。7种机器学习模型对玉米冠层底部的反演精度不同,其中MLPR和RFR在各个生育期下对LAI估算精度最高。玉米抽雄期的最佳LAI估算模型为MLPR,  $R^2$ 为0.91, rRMSE为5.1%。玉米吐丝期,RFR模型最佳估算结果  $R^2$ 为0.78, rRMSE为8.18%;籽粒建成期最佳估算模型为MLPR,  $R^2$ 为0.84, rRMSE为7.21%;乳熟期最佳估算模型为RFR,  $R^2$ 为0.82, rRMSE为6.18%;蜡熟期最佳估算模型为MLPR,  $R^2$ 为0.77, rRMSE为8.63%;成熟期最佳估算模型为MLPR,  $R^2$ 为0.80, rRMSE为11.01%。玉米单生育期LAI估算精度最高为玉米抽雄期,7个机器学习模型平均RMSE为0.16, rRMSE为7.38%, MAE为0.13。在玉米成熟期时,模型估算结果平均精度在所有生育期中最差,

表 2 影像变量与玉米 LAI 各生育期相关性排序结果

Tab. 2 Results of correlation between image variables and LAI growth periods of maize

相关系数排序	8月3日	8月10日	8月17日	8月24日	8月31日	9月8日	9月15日	全生育期
1	R Mean (MS)	R Mean (MS)	NIR Entropy	R Mean (MS)	R Mean (MS)	R Mean (MS)	NIR Entropy	NIR Homogeneity
2	RGBVI	G Variance	G Variance	R Entropy (MS)	ExGR	RE Mean	NIR Homogeneity	NIR Entropy
3	GLI	G Contrast	G Contrast	R Homogeneity (MS)	MGRVI	R Second Moment (MS)	NIR Dissimilarity	ExGR
4	g	B Contrast	R Variance (RGB)	R Variance (MS)	NDI	R Correlation (MS)	R Mean (MS)	COM
5	ExG	R Contrast (RGB)	B Variance	R Second Moment (MS)	GRVI	R Entropy (MS)	ExGR	GLI
6	R Dissimilarity (MS)	B Variance	R Contrast (RGB)	RE Mean	VARI	R Variance (MS)	NIR Second Moment	CIVE
7	RE Mean	R Variance (RGB)	NIR Second Moment	R Dissimilarity (MS)	ExR	MGRVI	VARI	ExG
8	R Variance (MS)	RE Mean	B Contrast (MS)	R Contrast (MS)	COM	VARI	COM	g
9	CIVE	G Dissimilarity	NIR Homogeneity	R (RGB)	GRRI	GRVI	GRVI	VEG
10	R Contrast (MS)	R Correlation (MS)	G Dissimilarity	R Mean (RGB)	R Mean (RGB)	NDI	MGRVI	RGBVI

注: 对 RGB 和 MS 中可见光波段进行区分, 变量后缀(RGB)为可见光数据源, (MS)为多光谱数据源。

表 3 玉米单生育期 LAI 估算结果

Tab. 3 Estimated results of maize LAI in single growth period

LAI 田间观测日期	精度指标	玉米 LAI 估测模型						平均值
		PLSR	RFR	SVR	MLPR	GBDT	LightGBM	
8月3日(抽雄期)	$R^2$	0.71	0.45	0.72	0.91	0.87	0.63	0.73
	RMSE	0.18	0.17	0.18	0.11	0.16	0.18	0.17
	rRMSE/%	8.01	7.43	7.88	5.10	7.33	8.13	7.76
	MAE	0.15	0.12	0.14	0.09	0.13	0.15	0.14
8月10日(吐丝期)	$R^2$	0.72	0.78	0.83	0.81	0.64	0.52	0.82
	RMSE	0.16	0.14	0.16	0.16	0.15	0.24	0.16
	rRMSE/%	9.50	8.18	9.56	9.10	8.77	14.02	9.14
	MAE	0.14	0.11	0.13	0.14	0.12	0.20	0.13
8月17日(籽粒建成期)	$R^2$	0.49	0.76	0.64	0.84	0.64	0.47	0.32
	RMSE	0.21	0.18	0.19	0.16	0.19	0.20	0.19
	rRMSE/%	9.20	7.78	8.46	7.21	8.30	8.89	8.43
	MAE	0.18	0.14	0.17	0.13	0.16	0.14	0.16
8月24日(乳熟期)	$R^2$	0.76	0.82	0.82	0.68	0.75	0.59	0.77
	RMSE	0.25	0.15	0.20	0.18	0.19	0.22	0.21
	rRMSE/%	10.15	6.18	8.14	7.47	7.99	9.04	8.46
	MAE	0.21	0.12	0.16	0.15	0.15	0.19	0.16
8月31日(蜡熟期)	$R^2$	0.75	0.64	0.90	0.86	0.77	0.47	0.75
	RMSE	0.21	0.16	0.18	0.20	0.20	0.22	0.21
	rRMSE/%	9.26	7.09	7.76	8.43	8.47	9.47	8.85
	MAE	0.19	0.14	0.15	0.16	0.16	0.18	0.17
9月8日(凹陷期)	$R^2$	0.70	0.42	0.69	0.77	0.81	0.64	0.67
	RMSE	0.19	0.17	0.17	0.16	0.18	0.20	0.21
	rRMSE/%	9.97	8.92	8.80	8.63	9.65	10.85	10.94
	MAE	0.16	0.14	0.12	0.12	0.15	0.16	0.17
9月15日(成熟期)	$R^2$	0.55	0.65	0.54	0.80	0.62	0.58	0.57
	RMSE	0.21	0.21	0.21	0.20	0.23	0.22	0.22
	rRMSE/%	11.93	11.65	11.76	11.01	12.79	12.02	11.95
	MAE	0.17	0.17	0.17	0.16	0.19	0.19	0.17

7个机器学习模型平均RMSE为0.21,平均rRMSE为11.87%,平均MAE为0.17。

各机器学习模型在玉米全生育期的反演结果(表4)显示,RFR模型表现最好, $R^2$ 为0.67,rRMSE为11.31%。与单生育期结果相似,MLPR在全生育期下取得了与RFR近乎相同的模型精度, $R^2$

为0.79,rRMSE为11.42%,这表明在玉米单生育期和全生育期下MLPR和RFR模型都具有较强的鲁棒性。玉米整个生育期内,LightGBM模型鲁棒性最差,rRMSE为16.57%。从结果上看,机器学习模型可以在玉米全生育期下对LAI进行有效估算。

表4 玉米全生育期LAI估算结果

Tab. 4 Estimated results of maize LAI during whole growth period

精度指标	玉米叶面积指数估算模型						
	PLSR	RFR	SVR	MLPR	GBDT	LightGBM	XGBoost
$R^2$	0.64	0.67	0.63	0.79	0.49	0.58	0.61
RMSE	0.28	0.20	0.27	0.21	0.22	0.30	0.26
rRMSE/%	15.61	11.31	15.23	11.42	12.07	16.57	14.67
MAE	0.22	0.16	0.22	0.16	0.18	0.25	0.21

玉米LAI垂直分层估算结果如图6所示(LAI-1~LAI-5)。LAI-1至LAI-5玉米单生育期最佳模型和估算精度分别为:LAI-1为抽雄期MLPR模型, $R^2$ 为0.91,rRMSE为5.1%;LAI-2为蜡熟期MLPR模型, $R^2$ 为0.92,rRMSE为8.52%;LAI-3为籽粒建成期RFR模型, $R^2$ 为0.7,rRMSE为12.64%;LAI-4为蜡熟期GBDT模型, $R^2$ 为0.72,rRMSE为14.94%;LAI-5为乳熟期RFR模型, $R^2$ 为0.3,rRMSE为19.25%。研究分析了在玉米不同高度LAI估算结果各模型的稳定性,在所有玉米生育期下,各LAI垂直分布稳定性最好的模型:LAI-1为MLPR模型,rRMSE为8.13%;LAI-2为XGBoost模型,rRMSE为12.98%;LAI-3为RFR模型,rRMSE为16.35%;LAI-4为RFR模型,rRMSE为20.39%;LAI-5为RFR模型,rRMSE为

23.87%。RFR模型相较于其他模型对于冠层上部3层LAI估算具有较好的稳定性,对玉米冠层下部2层LAI估算MLPR和XGBoost模型稳定性更好。

### 2.3 不同飞行高度和太阳高度角LAI估算结果

基于上述研究结果,本研究采用了RFR和MLPR2个LAI估算模型对9月17日(表5)和9月18日(表6)不同飞行高度和不同太阳高度角所采集的RGB和MS无人机影像进行验证,同时探讨了模型的鲁棒性。9月17日进行了2次飞行高度对照试验(上午、下午各5个飞行架次,共计10期数据)。RFR与MLPR模型在上午和下午无人机飞行高度30 m时对LAI估算精度最高。其中,RFR模型在9月17日上午飞行高度30 m时得到了最佳结果, $R^2$ 为0.66,rRMSE为12.02%,MLPR在9月17日下午飞行高度30 m时得到最佳LAI估算结果, $R^2$

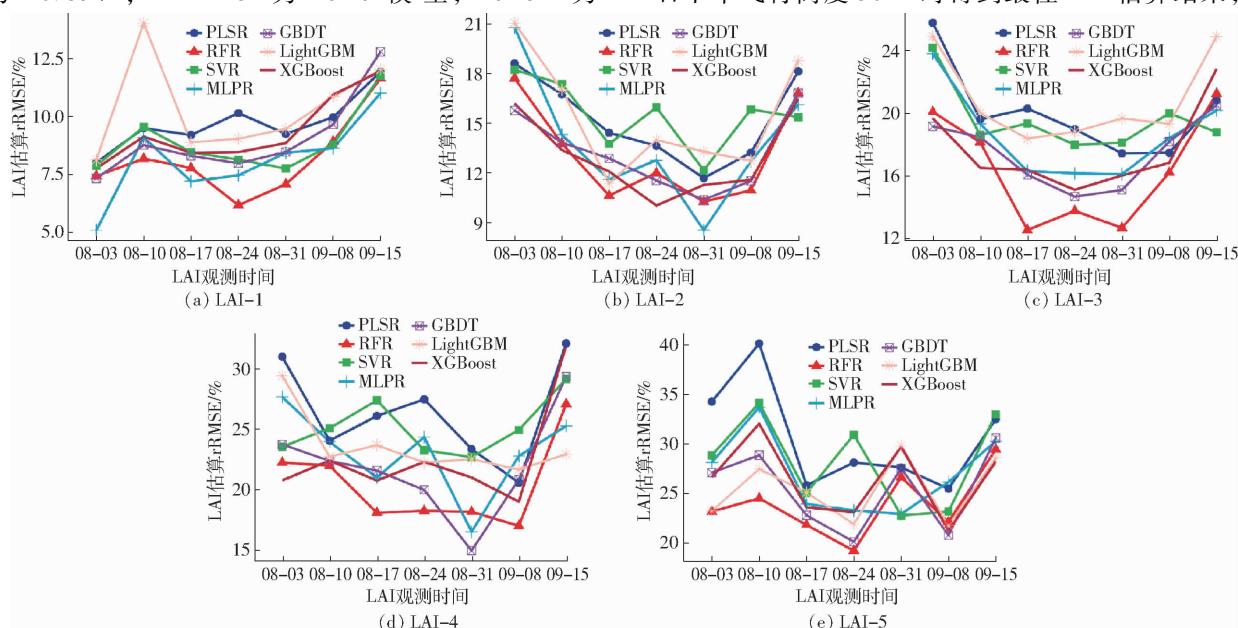


图6 玉米各生育期LAI垂直分布模型估测结果

Fig. 6 Estimation results of LAI vertical distribution model at different growth stages of maize

表 5 不同飞行高度下玉米 LAI 估算结果

Tab. 5 Estimation results of maize LAI at different flying altitudes

时间	飞行高度/ m	RFR				MLPR			
		R <sup>2</sup>	RMSE	rRMSE/%	MAE	R <sup>2</sup>	RMSE	rRMSE/%	MAE
9月17日上午	30	0.66	0.28	12.02	0.24	0.71	0.25	11.02	0.21
	50	0.66	0.30	13.19	0.24	0.58	0.31	13.43	0.23
	70	0.71	0.28	12.32	0.24	0.72	0.30	12.99	0.23
	90	0.50	0.34	14.94	0.26	0.66	0.27	11.95	0.22
	120	0.51	0.33	14.33	0.29	0.61	0.3	12.85	0.23
9月17日下午	30	0.69	0.29	12.63	0.24	0.73	0.25	10.97	0.21
	50	0.61	0.30	13.09	0.24	0.46	0.35	15.06	0.27
	70	0.60	0.31	13.27	0.24	0.55	0.31	13.45	0.26
	90	0.61	0.30	13.11	0.23	0.75	0.28	12.30	0.23
	120	0.65	0.31	13.54	0.26	0.61	0.30	12.88	0.24

表 6 不同太阳高度角下玉米 LAI 估算结果

Tab. 6 Maize LAI estimation results under different solar height angles

太阳高度角/ (°)	飞行时间	RFR				MLPR			
		R <sup>2</sup>	RMSE	rRMSE/%	MAE	R <sup>2</sup>	RMSE	rRMSE/%	MAE
24.53	08:00	0.57	0.31	13.54	0.26	0.55	0.32	13.82	0.28
35.18	09:00	0.69	0.27	11.75	0.22	0.62	0.29	12.46	0.23
45.38	10:00	0.66	0.31	13.31	0.25	0.63	0.28	12.05	0.22
53.04	11:00	0.47	0.34	14.92	0.28	0.64	0.28	12.34	0.24
56.52	12:00	0.47	0.33	14.56	0.26	0.52	0.32	13.89	0.25
54.28	13:00	0.60	0.33	14.38	0.27	0.58	0.34	14.75	0.25
47.69	14:00	0.67	0.35	14.98	0.24	0.56	0.35	15.01	0.28
37.62	15:00	0.42	0.38	16.42	0.31	0.60	0.34	14.57	0.25
26.39	16:00	0.43	0.36	15.48	0.29	0.47	0.33	14.23	0.25
15.66	17:00	0.57	0.34	15.00	0.28	0.56	0.28	12.35	0.23
4.67	18:00	0.60	0.27	11.95	0.22	0.49	0.34	14.62	0.26

为 0.73, rRMSE 为 10.97%。

RFR 和 MLPR 玉米 LAI 估算模型, 均是在早上获得的无人机遥感影像中估算 LAI 的精度最高。RFR 在 09:00 时获取了最佳结果,  $R^2$  为 0.69, rRMSE 为 11.75%。MLPR 在 10:00 得到了最佳结果,  $R^2$  为 0.63, rRMSE 为 12.05%。

### 3 讨论

#### 3.1 叶面积指数反演模型特征分析

在玉米各生育期, 根据各影像特征与玉米 LAI 相关系数由高到低的排序结果, 筛选了各生育期与 LAI 相关性较好的前 10 个遥感影像特征(表 2)。其中红光波段的均值纹理特征(R Mean), 在玉米 6 个生育期内均与玉米 LAI 有很好相关性, 其次是红边波段的均值纹理特征(RE Mean), 在 4 个玉米生育期内与 LAI 有良好的相关性。均值纹理特征在玉米多个生育期下都显示出了与 LAI 较好的相关性。在玉米生长发育后期(8月31日、9月8日和9月15日), 基于 RGB 无人机影像构建的 VARI、

GRVI 和 MGRVI 植被指数均与玉米 LAI 有较好的相关性。

大多数影像特征与玉米底部的 LAI 相关性最高, 这与 Sunscan 冠层分析仪测量 LAI 的原理有关。当光线到达冠层顶部, 首先被玉米雄穗进行初次遮挡与反射, 剩下的光线随着不断被玉米叶片和茎秆截获, 辐射通量逐渐下降, 最终在玉米冠层底部达到最低值<sup>[50]</sup>。但此条件仅限于玉米种植密度较小的情况, 当玉米种植密度较大时, LAI 直接观测相较于田间间接观测得到的值会有差异<sup>[51]</sup>。从表 2 与玉米 LAI 相关系数排序前 10 影像变量统计得出, 基于 RGB 影像所构建的影像特征在所有特征中的占比为 55.71%, 相较于其他 2 个数据源, 显示出与 LAI 更好的相关性。RGB 影像相较于 MS 和 TIR 影像数据, 有较高的影像分辨率, 可以更准确地捕捉玉米叶片信息, 如叶片边缘和尺寸等结构信息, 这可能是 RGB 影像特征与 LAI 有较高的相关系数的原因。在病害接种后, 玉米叶片通常会受到一定程度的损伤(图 7)。随着玉米生殖发育的推进, 病害程度逐



图 7 玉米不同病害等级下叶片受损情况

Fig. 7 Maize leaf damage under different disease levels

渐加深,叶片受损程度加大,玉米病斑破坏了原有叶片叶绿素,会导致影像中玉米叶片信息的丢失,这可能也是玉米冠层底部 LAI 估算精度随生育期逐渐下降的原因<sup>[52]</sup>。

### 3.2 玉米 LAI 估算模型精度分析

从表 3 可以看到,对玉米底层 LAI 观测最佳时期为玉米抽雄期。抽雄期是玉米生长发育成熟时期,此时提供营养的器官逐渐静止生长至停止生长,到玉米吐丝期时,所有的玉米叶片都已经展开。从玉米抽雄吐丝期以后,植株会进入以玉米籽粒生长为生长发育中心的生殖生长阶段。此时,营养供给主要集中于雄穗与雌穗,玉米底层叶片逐渐枯萎脱落,对于整个玉米生长阶段而言,玉米抽雄期是 LAI 观测最大值阶段,此时叶片均已展开,叶片也较为健康,从无人机影像中可以提取到的底层 LAI 信息最大,因此在玉米抽雄期估算 LAI 得到的精度最高。随着玉米生殖生长的不断进行,底层叶片枯萎,会导致影像中玉米叶片信息量下降。在玉米生殖发育阶段,RFR 和 MLP 模型显示了更好的 LAI 估算精度,这与 CASTRO-VALDECANTOS 等<sup>[53]</sup>的结论一致。MLP 模型对于其他机器学习模型而言,非线性拟合能力更强,且具有高阶特征组合的特点,其可以从大量的特征中学到其中的信息,并给出正确的预测结果。同时,MLP 泛化能力更强,可以将高维稀疏特征降低为低维稠密的向量,使得模型具备泛化能力,有效地从特征中学到有用信息,因而有效提升了模型的泛化能力<sup>[54]</sup>。RFR 模型可以从高维影像特征中,通过特征重要性排序得到比较重要的特征。相较于其他单独的决策树模型而言,RFR 模型集成了多个决策树,模型不易出现过拟合的现象,因此模型的泛化能力得到了增强<sup>[55]</sup>。集成学习如 XGBoost、GBDT、LightGBM 等模型需要数据分布足够时,才能有较好的精度。而 LAI 冠层垂直分布数据分布不平衡,尤其是冠层顶部,数据过于集中,因

此导致了 LAI 估算精度下降(图 3)<sup>[56]</sup>。

玉米冠层顶部上两层 LAI 反演结果波动相对较大,最下层反演结果最稳定(图 8),随生育时期的进展精度呈现逐渐降低的趋势。倒数第 2 层和第 3 层玉米 LAI 反演精度呈现先增加后降低的趋势。同时玉米冠层 LAI 垂直分布倒数第 1 层到第 3 层即玉米穗位叶及其以下部分,在玉米各个生育期下对 LAI 估算误差 rRMSE 多数在 20% 以下,证明无人机多模态数据具有对玉米功能叶层 LAI 反演的潜力,可以准确掌握与玉米产量高度相关的穗位叶长势信息。玉米功能叶片 LAI 的准确估计也为玉米估产提供了潜在的表型参数数据支撑。LAI 垂直分布精确估算,对于育种工程中研究玉米功能结构空间分布提供了有效的技术手段<sup>[57]</sup>。目前研究仅基于光学遥感传感器对玉米 LAI 垂直分布进行了检测。现有研究表明,基于 LiDAR 传感器获取的结构信息,也有助于获取玉米叶片结构信息,因此在未来的研究中需要进一步探究无人机 LiDAR 数据源对玉米 LAI 估算的潜力,充分发挥无人机多源遥感数据的优势,提高玉米 LAI 垂直分布估算精度<sup>[58]</sup>。

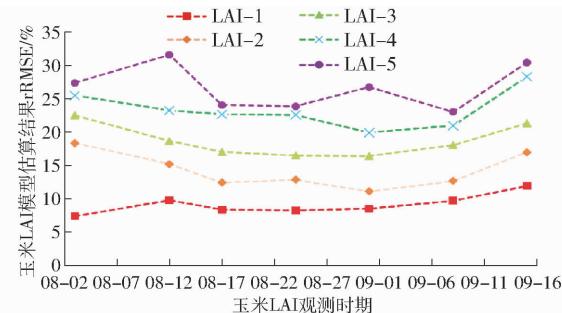


图 8 玉米 LAI 垂直分布各生育期模型估测结果平均值

Fig. 8 Average estimation results of maize vertical distribution in each growth period

研究构建的 7 个 LAI 估算模型,在玉米单生育期下对 LAI 垂直分布观测误差的平均 rRMSE 分别为:9.1% (LAI - 1)、14.19% (LAI - 2)、18.62%

(LAI - 3)、23.29% (LAI - 4) 和 26.7% (LAI - 5)。从结果上看,随着玉米 LAI 观测高度的上升,模型对玉米 LAI 观测精度不断下降。太阳光截获量最大的位置,通常位于玉米冠层底部,在此处测量的玉米 LAI 更能体现整个玉米冠层的 LAI 状况。随着观测高度的增加玉米 LAI 逐渐下降,逐渐与影像信息量不匹配,这可能是导致其他冠层高度 LAI 相较于底层 LAI 精度低的原因。

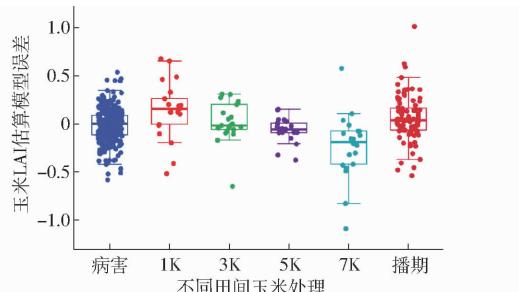


图 9 不同田间试验下玉米 LAI 模型误差分布

Fig. 9 LAI error distribution of model estimation result under different field experiments

在不同田间试验条件下,统计了玉米 LAI 模型估算结果与实测值的差值(图 9)。病害和播期试验每个小区都属于不同的玉米品种,且种植密度一致,数据分布相较于密度试验更好,因此误差处于合理范围。在密度试验 1K 和 7K 条件下,出现了对 LAI 明显的高估和低估现象。玉米种植密度越高,越容易出现光谱饱和现象,即随着玉米生长,田间 LAI 观测值还在上升,而从影像中获取的光谱反射率到达高值后变化幅度不大。在玉米种植密度较低时,通过剔除土壤像素点,可以保留所有的玉米叶片信息,低种植密度下,也很少存在叶片重叠的现象,这导致从影像中获取的信息量比采集到的 LAI 信息量高,因此高估了玉米 LAI。在玉米高种植密度下,玉米冠层在无人机正射影像中已经郁闭,从中提取的影像信息量不再发生变化,然而实际玉米 LAI 还在增长,这是导致高种植密度下,玉米 LAI 低估的原因。

### 3.3 不同飞行高度和太阳高度角对 LAI 估算的影响

本研究分析了多种不同飞行高度和太阳高度角对玉米 LAI 估算的影响。从结果上看,当无人机飞得越低,影像分辨率越高时,LAI 估算精度越高。随着无人机飞行高度(30~120 m)的不断上升,分辨率逐渐下降严重,此时会丢失大量的玉米冠层形态结构细节,影像中叶片容易与土壤产生混合像元,分割土壤背景时,部分像素会被错误地识别为土壤,因此导致玉米在影像中的信息量下降。因此,对于玉米 LAI 的观测,无人机飞行高度低可以较好地保持影像特征及信息量,从而提升 LAI 观测精度。在不同太阳高度角试验中,在 09:00—10:00 这个区间对

玉米 LAI 观测精度最高,此时太阳高度角位于 35.18°~47.89° 范围,当日最高太阳高度角为 56.66°(图 10)。

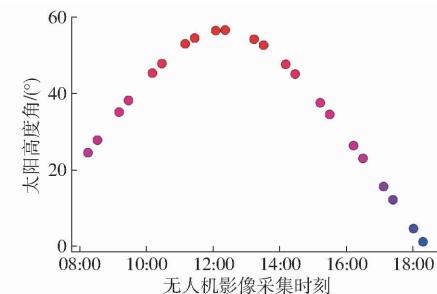


图 10 无人机影像数据采集时段和太阳高度角

Fig. 10 UAV image data collection time and sun altitude angle

已有研究显示,在晴天条件下,不同太阳高度角下观测得到的 LAI 不同<sup>[59]</sup>。晴天条件下,虽然看起来天气条件比较稳定,但高层的大气仍会存在变动,因其产生的扰动会影响到达地表的太阳辐射变化。同时,晴天下的太阳高度角变化,也会导致最终射入玉米冠层的太阳辐射有所差异<sup>[60]</sup>。从结果上看 09:00—10:00 的 LAI 观测精度较好,从植物生理上而言,随着时间的增加,地表温度上升,高温和干旱会导致玉米叶片卷叶,LAII 下降,这可能是导致在早晨观测 LAI 精度较高的原因。同时在早晨,太阳高度角较小,LAII 会比正常情况下偏大一些。当太阳高度角最大时,LAII 观测值会低一些<sup>[61]</sup>。因此,早晨玉米 LAI 更能显示整体的生长状况,模型得到了较高的观测精度。

## 4 结论

(1) 从单生育和全生育期 LAI 估算结果精度可以得出,MLPR 和 RFR 模型具有最好的鲁棒性和稳定性。2 个模型全生育期下对玉米 LAI 估算误差 rRMSE 为 11.31% (MLPR) 和 11.42% (RFR)。

(2) 在玉米各个生育期构建的 LAI - 1、LAI - 2 以及 LAI - 3 的估算模型误差(rRMSE)多数在 20% 以下,表明无人机多模态数据具有对玉米穗位叶精准 LAI 反演的潜力。

(3) 从不同飞行高度和太阳高度角试验中可以得出,无人机飞行高度越低对玉米 LAI 估算精度越高,当飞行高度为 30 m 时 MLPR 模型精度  $R^2$  为 0.73, rRMSE 为 10.97%。09:00—10:00, 玉米 LAI 观测精度最高。

(4) 无人机多源遥感影像数据可以有效地对玉米冠层 LAI 垂直分布进行准确观测,可以掌握玉米 LAI 垂直方向上的空间分布,及时了解各个功能叶片的健康状况,为及时调整田间管理措施提供辅助。

## 参考文献

- [1] GHOLZ H L. Environmental limits on aboveground net primary production, leaf area, and biomass in vegetation zones of the Pacific Northwest[J]. *Ecology*, 1982, 63(2): 469–481.
- [2] CASADESÚS J, VILLEGRAS D. Conventional digital cameras as a tool for assessing leaf area index and biomass for cereal breeding[J]. *J. Integr. Plant Biol.*, 2014, 56(1): 7–14.
- [3] SIMONICH S L, HITES R A. Importance of vegetation in removing polycyclic aromatic hydrocarbons from the atmosphere[J]. *Nature*, 1994, 370(6484): 49–51.
- [4] JONCKHEERE I, FLECK S, NACKAERTS K, et al. Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography[J]. *Agric. for Meteorol.*, 2004, 121(1–2): 19–35.
- [5] GARRIGUES S, LACAZE R, BARET F, et al. Validation and intercomparison of global leaf area index products derived from remote sensing data[J]. *J. Geophys Res. Biogeosci.*, 2008, 113(2): 1–20.
- [6] GOWER S T, KUCHARIK C J, NORMAN J M. Direct and indirect estimation of leaf area index, f(APAR), and net primary production of terrestrial ecosystems[J]. *Remote Sens. Environ.*, 1999, 70(1): 29–51.
- [7] SU H X, BAI F, LI G Q. Seasonal dynamics in leaf area index in three typical temperate montane forests of China: a comparison of multi-observation methods[J]. *Chinese Journal of Plant Ecology*, 2012, 36(3): 231–242.
- [8] FANG H L, BARET F, PLUMMER S, et al. An overview of global leaf area index (LAI): methods, products, validation, and applications[J]. *Rev. Geophys.*, 2019, 57(3): 739–799.
- [9] YAN G J, HU R H, LUO J H, et al. Review of indirect optical measurements of leaf area index: recent advances, challenges, and perspectives[J]. *Agric. for Meteorol.*, 2019, 265(1): 390–411.
- [10] HAMES J S, COOTER E, PILANT A N, et al. Comparison of EPIC – simulated and MODIS – derived leaf area index (LAI) across multiple spatial scales[J]. *Remote Sens.*, 2020, 12(17): 2764–2786.
- [11] KANNING M, KUHLING I, TRAUTZ D, et al. High-resolution UAV – based hyperspectral imagery for LAI and chlorophyll estimations from wheat for yield prediction[J]. *Remote Sens.*, 2018, 10(12): 2000.
- [12] SHAO G, HAN W, ZHANG H, et al. Mapping maize crop coefficient  $K_c$  using random forest algorithm based on leaf area index and UAV-based multispectral vegetation indices[J]. *Agric. Water Manag.*, 2021, 252(1): 106906.
- [13] LEI L, QIU C, LI Z, et al. Effect of leaf occlusion on leaf area index inversion of maize using UAV – LiDAR data[J]. *Remote Sens.*, 2019, 11(9): 1067.
- [14] 王翔宇, 杨菡, 李鑫星, 等. 基于无人机可见光谱遥感的玉米长势监测[J]. 光谱学与光谱分析, 2021, 41(1): 265–270.  
WANG Xiangyu, YANG Han, LI Xinxing, et al. Research on maize growth monitoring based on visible spectrum of UAV remote sensing[J]. *Spectroscopy and Spectral Analysis*, 2021, 41(1): 265–270. (in Chinese)
- [15] 徐洪刚, 陈震, 程千, 等. 无人机多源光谱反演大田夏玉米叶面积指数[J]. 灌溉排水学报, 2021, 40(8): 42–49.  
XU Honghang, CHEN Zhen, CHENG Qian, et al. Leaf area index of summer maize estimated using UAV-based multispectral imageries[J]. *Journal of Irrigation and Drainage*, 2021, 40(8): 42–49. (in Chinese)
- [16] MAIMAITIJIANG M, GHULAM A, SIDIKE P, et al. Unmanned aerial system (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine[J]. *ISPRS J. Photogramm Remote Sens.*, 2017, 134(1): 43–58.
- [17] 王纪华, 黄文江, 劳彩莲, 等. 运用 PLS 算法由小麦冠层反射光谱反演氮素垂直分布[J]. 光谱学与光谱分析, 2007, 27(7): 1319–1322.  
WANG Jihua, HUANG Wenjiang, LAO Cailian, et al. Inversion of winter wheat foliage vertical distribution based on canopy reflected spectrum by partial least squares regression method[J]. *Spectroscopy and Spectral Analysis*, 2007, 27(7): 1319–1322. (in Chinese)
- [18] MANANZE S, PÔÇAS I, CUNHA M. Retrieval of maize leaf area index using hyperspectral and multispectral data[J]. *Remote Sens.*, 2018, 10(12): 1942.
- [19] CHEN T, GUESTRIN C. Xgboost: a scalable tree boosting system[C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016.
- [20] ZHANG X, DENG T, JIA G. Nuclear spin-spin coupling constants prediction based on XGBoost and LightGBM algorithms[J]. *Mol. Phys.*, 2019, 118(14): 1–10.
- [21] DUAN B, LIU Y, GONG Y, et al. Remote estimation of rice LAI based on Fourier spectrum texture from UAV image[J]. *Plant Methods*, 2019, 15(1): 1–12.
- [22] LI S, YUAN F, ATA-UU-KARIM S T, et al. Combining color indices and textures of UAV-based digital imagery for rice LAI estimation[J]. *Remote Sens.*, 2019, 11(15): 1763–1784.
- [23] SONG Z, ZHANG Z, YANG S, et al. Identifying sunflower lodging based on image fusion and deep semantic segmentation with UAV remote sensing imaging[J]. *Computers Electronics in Agriculture*, 2020, 179(1): 105–120.
- [24] AHMAD I S, REID J F. Evaluation of colour representations for maize images[J]. *J Agric. Eng. Res.*, 1996, 63(3): 185–195.
- [25] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation[J]. *Remote Sens. Environ.*, 1979, 8(2): 127–150.

- [26] WOEBBECKE D M, MEYER G E, VON BARGEN K, et al. Plant species identification, size, and enumeration using machine vision techniques on near-binary images[C]//Proceedings of the Optics in Agriculture and Forestry, 1993.
- [27] WOEBBECKE D M, MEYER G E, VONBARGEN K, et al. Color indexes for weed identification under various soil, residue, and lighting conditions[J]. Trans. Am. Soc. Agric. Eng., 1995, 38(1): 259–269.
- [28] KAWASHIMA S, NAKATANI M. An algorithm for estimating chlorophyll content in leaves using a video camera[J]. Ann. Bot., 1998, 81(1): 49–54.
- [29] LOUHAICHI M, BORMAN M M, JOHNSON D E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat[J]. Geocarto. Int., 2001, 16(1): 65–70.
- [30] GITELSON A A, KAUFMAN Y J, STARK R, et al. Novel algorithms for remote estimation of vegetation fraction[J]. Remote Sens. Environ., 2002, 80(1): 76–87.
- [31] MAO W, WANG Y, WANG Y. Real-time detection of between-row weeds using machine vision[C]//Proceedings of the 2003 ASAE Annual Meeting, 2003.
- [32] HAGUE T, TILLETT N D, WHEELER H. Automated crop and weed monitoring in widely spaced cereals[J]. Precis. Agric., 2006, 7(1): 21–32.
- [33] SABERIOON M M, AMIN M S M, ANUAR A R, et al. Assessment of rice leaf chlorophyll content using visible bands at different growth stages at both the leaf and canopy scale[J]. Int. J. Appl. Earth Obs. Geoinf., 2014, 32(1): 35–45.
- [34] GUIJARRO M, PAJARES G, RIOMOROS I, et al. Automatic segmentation of relevant textures in agricultural images[J]. Comput. Electron. Agric., 2011, 75(1): 75–83.
- [35] GAMON J A, SURFUS J S. Assessing leaf pigment content and activity with a reflectometer[J]. New Phytol., 1999, 143(1): 105–117.
- [36] BENDIG J, YU K, AASEN H, et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley[J]. Int. J. Appl. Earth Obs. Geoinf., 2015, 39(1): 79–87.
- [37] HUETE A, DIDAN K, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. Remote Sens. Environ., 2002, 83(1–2): 195–213.
- [38] GITELSON A A, KAUFMAN Y J, MERZLYAK M N. Use of a green channel in remote sensing of global vegetation from EOS – MODIS[J]. Remote Sens. Environ., 1996, 58(3): 289–298.
- [39] GITELSON A A, MERZLYAK M N. Remote estimation of chlorophyll content in higher plant leaves[J]. Int. J. Remote Sens., 1997, 18(12): 2691–2697.
- [40] RAMOEOLO A, SKIDMORE A K, CHO M A, et al. Regional estimation of savanna grass nitrogen using the red-edge band of the spaceborne RapidEye sensor[J]. Int. J. Appl. Earth Obs. Geoinf., 2012, 19(1): 151–162.
- [41] PORTZ G, MOLIN J P, JASPER J. Active crop sensor to detect variability of nitrogen supply and biomass on sugarcane fields [J]. Precis. Agric., 2012, 13(1): 33–44.
- [42] QI J, CHEHBOUNI A, HUETE A R, et al. A modified soil adjusted vegetation index[J]. Remote Sens. Environ., 1994, 48(2): 119–126.
- [43] GENEVIÈVE R, MICHAEL S, FRÉDÉRIC B. Optimization of soil-adjusted vegetation indices[J]. Remote Sens. Environ., 1996, 55(2): 95–107.
- [44] HABOUDANE D, MILLER J R, PATTEY E, et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture[J]. Remote Sens. Environ., 2004, 90(3): 337–352.
- [45] GITELSON A, MERZLYAK M N. Quantitative estimation of chlorophyll-ausing reflectance spectra: experiments with autumn chestnut and maple leaves[J]. J. Photochem. Photobiol. B. Biol., 1994, 22(3): 247–252.
- [46] MYNNENI R, WILLIAMS D. On the relationship between FAPAR and NDVI[J]. Remote Sens. Environ., 1994, 49(3): 200–211.
- [47] CHEN J M. Evaluation of vegetation indices and a modified simple ratio for boreal applications[J]. Can. J. Remote. Sens., 1996, 22(3): 229–242.
- [48] NICHOL J E, SARKER M L R. Improved biomass estimation using the texture parameters of two high-resolution optical sensors [J]. IEEE Trans. Geosci. Remote Sens., 2011, 49(3): 930–948.
- [49] LIU S, JIN X, NIE C, et al. Estimating leaf area index using unmanned aerial vehicle data: shallow vs. deep machine learning algorithms[J]. Plant Physiol., 2021, 187(3): 1551–1576.
- [50] KIRA O, NGUY-ROBERTSON A L, ARKEBAUER T J, et al. Toward generic models for green LAI estimation in maize and soybean: satellite observations[J]. Remote Sens., 2017, 9(4): 318–334.
- [51] 石晶明, 袁述, 居为民. 基于 LAI-2200 冠层分析仪的水稻叶面积指数测定条件[J]. 江苏农业科学, 2022, 50(10): 208–216.  
SHI Jingming, YUAN Shu, JU Weimin. Determination conditions of rice leaf area index based on LAI-2200 canopy analyzer [J]. Jiangsu Agricultural Sciences, 2022, 50(10): 208–216. (in Chinese)
- [52] WARD J M, STROMBERG E L, NOWELL D C, et al. Gray leaf spot: a disease of global importance in maize production[J]. Plant Disease, 1999, 83(10): 884–895.

- ZHENG Nengxin. Face recognition based on wavelet transform and HOG feature [D]. Hangzhou: Zhejiang Gongshang University, 2020. (in Chinese)
- [21] 王俊杰,赵勇,闵令江,等.奶山羊品种资源现状和育种技术进展[J].家畜生态学报,2017,38(9):7–12.
- WANG Junjie, ZHAO Yong, MIN Lingjiang, et al. Prospects of genetic resources and breeding techniques in dairy goat (*Capra hircus*) [J]. Journal of Domestic Animal Ecology, 2017, 38(9): 7–12. (in Chinese)
- [22] NOOR A, ZHAO Y, KOUBAA A, et al. Automated sheep facial expression classification using deep transfer learning [J]. Computers and Electronics in Agriculture, 2020, 175: 105528.
- [23] 韩丁,王斌,王亮,等.基于改进 VGGNet 的羊个体疼痛识别方法[J].农业机械学报,2022,53(6):311–317.
- HAN Ding, WANG Bin, WANG Liang, et al. Individual pain recognition method of sheep based on improved VGGNet [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 311–317. (in Chinese)
- [24] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity [J]. IEEE Transactions on Image Process, 2004, 13(4): 600–612.
- [25] 王荣,史再峰,高荣华,等.多变环境下基于多尺度卷积网络的猪个体识别[J].江西农业大学学报,2020,42(2):391–400.
- WANG Rong, SHI Zaifeng, GAO Ronghua, et al. Individual identification of pigs based on multi-scale convolutional network in a variable environment [J]. Acta Agriculturae Universitatis Jiangxiensis, 2020, 42(2): 391–400. (in Chinese)
- [26] 马宏兴,张森,董凯兵,等.基于改进 YOLO v5 的宁夏草原蝗虫识别模型研究[J].农业机械学报,2022,53(11):270–279.
- MA Hongxing, ZHANG Miao, DONG Kaibing, et al. Research of locust recognition in Ningxia grassland based on improved YOLO v5 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(11): 270–279. (in Chinese)
- [27] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C] // Advances in Neural Information Processing Systems, 2012: 1097–1105.
- [28] SIMONYAN K, ZISSELMAN A. Very deep convolutional networks for large-scale image recognition [C] // International Conference on Learning Presentations, 2015: 1–14.
- [29] SZEGEDY C, WEI L, JIA Y, et al. Going deeper with convolutions [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1–9.
- [30] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [31] HUANG G, LIU Z, LAURENS V D M, et al. Densely connected convolutional networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700–4708.

(上接第 193 页)

- [53] CASTRO-VALDECANTOS P, APOLO-APOLO O, PÉREZ-RUIZ M, et al. Leaf area index estimations by deep learning models using RGB images and data fusion in maize [J]. Precis. Agric., 2022, 23(6): 1949–1966.
- [54] FORTIN J, ANCTIL F, PARENT L. Comparison of multiple-layer perceptrons and least squares support vector machines for remote-sensed characterization of in-field LAI patterns—a case study with potato [J]. Can. J. Remote Sens., 2014, 40(2): 75–84.
- [55] CHENG Q, XU H, FEI S, et al. Estimation of maize LAI using ensemble learning and UAV multispectral imagery under different water and fertilizer treatments [J]. Agriculture, 2022, 12(8): 1267–1288.
- [56] ZHANG P, ZHU X, SHI Y, et al. Robust ensemble learning for mining noisy data streams [J]. Decision Support Systems, 2011, 50(2): 469–479.
- [57] DWYER L, STEWART D, HAMILTON R, et al. Ear position and vertical distribution of leaf area in corn [J]. Agron. J., 1992, 84(3): 430–438.
- [58] NIE S, WANG C, DONG P, et al. Estimating leaf area index of maize using airborne discrete-return LiDAR data [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(7): 3259–3266.
- [59] DE WASSEIGE C, BASTIN D, DEFOURNY P. Seasonal variation of tropical forest LAI based on field measurements in Central African Republic [J]. Agric. for Meteorol., 2003, 119(3–4): 181–194.
- [60] 姚延娟, 阎广建, 王锦地. 多光谱多角度遥感数据综合反演叶面积指数方法研究 [J]. 遥感学报, 2005, 1(2): 117–122.
- YAO Yanjuan, YAN Guangjian, WANG Jindi. The approach on leaf area index inversion using multiangular and multispectral data sets [J]. National Remote Sensing Bulletin, 2005, 1(2): 117–122. (in Chinese)
- [61] 王龑, 田庆久, 黄彦, 等. 太阳高度角变化对小麦叶面积指数观测的影响 [J]. 遥感信息, 2013, 28(6): 44–57.
- WANG Yan, TIAN Qingjiu, HUANG Yan, et al. Effect of solar altitude angle variation on the observation of wheat leaf area index [J]. Remote Sensing Information, 2013, 28(6): 44–57. (in Chinese)