

引用格式: Zhang Yaqian, Luo Shezhou, Wang Cheng, *et al.* Combining UAV LiDAR and Hyperspectral Data for Retrieving Maize Leaf Area Index[J]. Remote Sensing Technology and Application, 2022, 37(5): 1097-1108. [张亚倩, 骆社周, 王成, 等. 联合无人机激光雷达和高光谱数据反演玉米叶面积指数[J]. 遥感技术与应用, 2022, 37(5): 1097-1108.]

DOI: 10.11873/j.issn.1004-0323.2022.5.1097

## 联合无人机激光雷达和高光谱数据反演玉米叶面积指数

张亚倩<sup>1</sup>, 骆社周<sup>1</sup>, 王成<sup>2</sup>, 习晓环<sup>2</sup>, 聂胜<sup>2</sup>, 黎东<sup>2</sup>, 李光辉<sup>3</sup>

(1. 福建农林大学 资源与环境学院, 福建 福州 350002;

2. 中国科学院空天信息创新研究院, 北京 100094;

3. 河南省航空物探遥感中心, 河南 郑州 450053)

**摘要:** 叶面积指数(Leaf Area Index, LAI)是作物长势监测及产量估算的重要指标, 准确高效的LAI反演对农田经济的宏观管理具有重要作用。研究探索了联合无人机激光雷达(Light Detection and Ranging, LiDAR)和高光谱数据反演玉米叶面积指数的潜力, 并分析了LiDAR数据不同采样尺寸、高度阈值、点密度对LAI反演精度的影响同时确定三者的最优值。该研究分别从重采样的LiDAR数据和高光谱影像中提取了LiDAR变量和植被指数, 然后基于偏最小二乘回归(Partial Least Square Regression, PLSR)和随机森林(Random Forest, RF)回归两种算法分别利用LiDAR变量、植被指数、联合LiDAR变量和植被指数构建预测模型, 并确定反演玉米LAI的最优预测模型。结果表明: 反演玉米LAI的最优采样尺寸、高度阈值、点密度分别为5.5 m、0.55 m、18 points/m<sup>2</sup>, 研究发现最高的点密度(420 points/m<sup>2</sup>)并没有产生最优的玉米LAI反演精度, 因此单独依靠增加点密度的方法提高LAI的反演精度并不可靠。基于LiDAR变量获得的LAI反演精度(PLSR:  $R^2=0.874$ , RMSE=0.317; RF:  $R^2=0.942$ , RMSE=0.222)高于基于植被指数获得的LAI反演精度(PLSR:  $R^2=0.741$ , RMSE=0.454; RF:  $R^2=0.861$ , RMSE=0.338), 而使用组合变量构建预测模型的反演精度(PLSR:  $R^2=0.885$ , RMSE=0.304; RF:  $R^2=0.950$ , RMSE=0.203)优于使用单一变量建立的LAI预测模型, 其中利用联合LiDAR变量和植被指数建立的随机森林回归模型为最优预测模型。因此, 将两种数据源融合在提高植被LAI反演精度方面具有一定的潜力。

**关键词:** 无人机激光雷达; 高光谱; 叶面积指数; 玉米; 点云密度

**中图分类号:** TP958.98; S513 **文献标志码:** A **文章编号:** 1004-0323(2022)05-1097-12

### 1 引言

我国是粮食需求大国, 粮食生产具有一定的压力, 玉米作为我国重要的粮食作物之一, 在我国种植分布广泛, 玉米稳定生产对我国的粮食安全具有重要意义<sup>[1]</sup>。叶面积指数影响植物的光合作用、呼

吸作用、蒸腾作用和碳循环等生理过程, 是作物生长状况监测及产量估算的重要指标<sup>[2]</sup>, 准确高效地获取叶面积指数对产量估算及生态建模具有重要意义<sup>[3-4]</sup>。

传统的LAI测量方法耗时耗力, 成本高、效率低, 只适合小尺度田间研究, 难以应用于空间大区

收稿日期: 2021-10-08; 修订日期: 2022-07-13

基金项目: 国家自然科学基金项目(41871264, 42101325)。

作者简介: 张亚倩(1996—), 女, 江西新余人, 硕士研究生, 主要从事激光雷达植被遥感研究。E-mail: xzyq771@163.com

通讯作者: 骆社周(1979—), 男, 河南驻马店人, 教授, 主要从事激光雷达植被遥感研究。E-mail: luoshezhou@163.com

域的植被信息采集,其中人工实地直接测量还具有一定的破坏性<sup>[5-7]</sup>。然而,遥感技术在植被参数提取上的应用很好地解决了传统测量存在的缺陷,并且能够实现 LAI 动态变化的实时监测。无人机(Unmanned Aerial Vehicle, UAV)作为一项新兴技术,近年来成为许多学者的研究热点<sup>[8-9]</sup>,以无人机为搭载平台的低空遥感弥补了机载遥感和星载遥感等高空遥感存在的不足,因其飞行灵活、操作简单、数据获取周期短、空间分辨率高、经济实用等优势,被广泛应用于 LAI 的遥感监测<sup>[10-11]</sup>。无人机被动遥感搭载的传感器通常有数码相机、多光谱相机和高光谱相机,相比于前两种传感器,高光谱相机具有高光谱分辨率的性能,可以获取连续的、大量的目标光谱以及更为丰富的地物光谱信息,从而能较为精确地监测作物 LAI<sup>[12-14]</sup>。然而被动光学遥感技术受大气条件、土壤背景等影响,只能监测作物冠层表面的特征,难以获取作物的三维垂直结构信息。同时,当 LAI 达到某一阈值时,植被密集且低矮区域的植被指数容易趋向饱和,导致植被指数与 LAI 不再呈线性增加,往往使获得的 LAI 偏低从而影响它的反演精度<sup>[15]</sup>。

激光雷达是一种主动遥感技术,可以实现植被 3D 立体扫描,其发射的激光脉冲能穿透植被冠层,可以获取植被的三维垂直结构特征,能够克服被动光学遥感存在的饱和等问题,已经成为精确估算高度、生物量、LAI 等植被参数的一种非常有用的工具<sup>[16-18]</sup>。无人机激光雷达技术在农业上的应用处于早期阶段,但基于无人机遥感平台的激光雷达技术,所获得的点云数据精度高、密度高,在农业研究中具有巨大的应用潜力。Lei 等<sup>[19]</sup>利用无人机激光雷达数据针对叶片遮挡影响叶面积指数反演结果进行了定量分析,为作物冠层结构分析提供重要指导依据。但是利用激光雷达数据的作物 LAI 反演缺乏植被光谱信息,有研究结合激光雷达和高光谱技术在植被参数提取方面的优势,实现两种数据源优势互补从而提高叶面积指数的反演精度。Luo 等<sup>[20]</sup>联合高光谱影像与机载激光雷达数据实现了玉米高度、生物量及叶面积指数的估算,研究发现这一方法估算的高度、生物量及叶面积指数与单一数据源相比的预测精度更高。

本研究基于无人机遥感飞行平台获取的激光雷达数据与高光谱影像实现玉米叶面积指数反演,探索融合无人机激光雷达和高光谱数据在玉米叶

面积指数反演方面的潜力。针对这一目标,本研究开展了以下 4 项研究内容:①研究不同采样尺寸、高度阈值及点密度对叶面积指数反演精度的影响,并确定这三者的最优值;②确定参与叶面积指数反演的最佳激光雷达特征变量和植被指数;③联合无人机激光雷达数据和高光谱影像反演玉米叶面积指数;④评价玉米叶面积指数的反演精度,确定最优预测模型。

## 2 数据与方法

### 2.1 研究区概况及地面数据获取

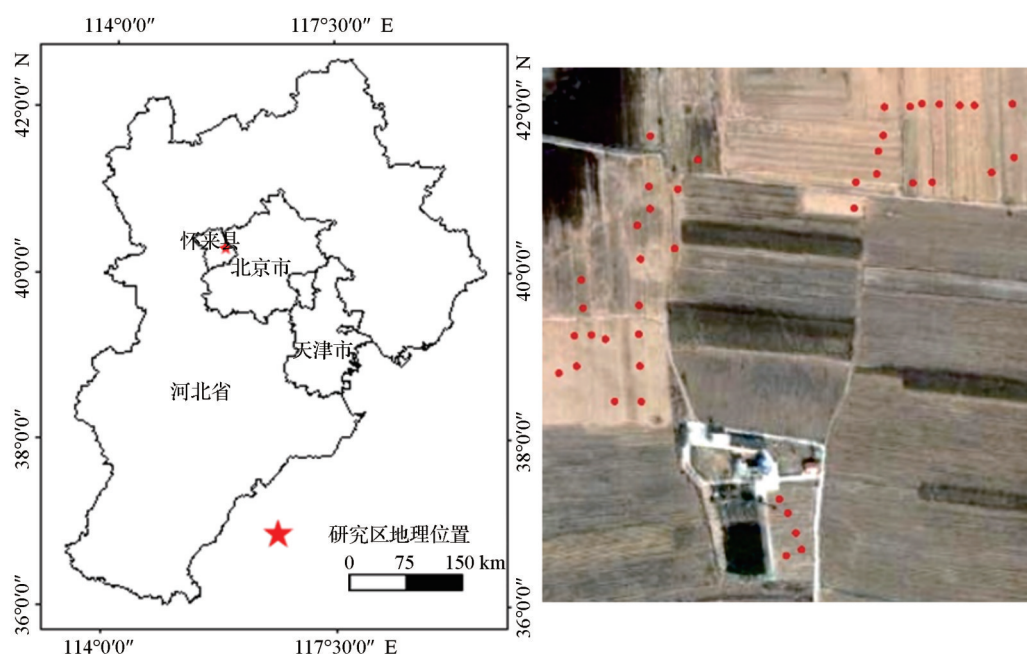
研究区位于河北省张家口市怀来县东花园镇中国科学院怀来遥感综合试验站,处在燕山山脉北侧,永定河上游,河川纵贯,地形复杂。研究区属温带大陆性季风气候,四季分明、昼夜温差大,最高气温可达 40℃以上,最低气温可达-20℃以下,年均降水量 396 mm。以沙性土壤为主,玉米为主要种植作物,该研究选取了 41 块玉米样地,每一块样地为 10 m×10 m 的正方形,

地块内平均行距 50 cm,平均株距 40 cm。玉米 LAI 野外实地测量数据采集日期为 2019 年 7 月 20 日—7 月 22 日(穗期),使用 LAI-2200 冠层分析仪对 41 块样地内的 LAI 进行测量,将测量结果的平均值作为每块样地的 LAI,同时手持 GPS 精确定位每块样地并记录下样地的中心坐标。研究区和 41 个玉米样本位置如图 1 所示。

### 2.2 无人机激光雷达数据处理及获取

2019 年 7 月使用六旋翼无人机搭载 Riegl VUX-1 扫描仪采集 LiDAR 数据。无人机飞行平台的平均飞行高度 150 m,扫描角度范围±46°,飞行旁向重叠 70%,LiDAR 数据平均点密度约为 420 points/m<sup>2</sup>。激光雷达点云数据被存储为标准的 LAS 格式,主要包括 X、Y、Z 三维坐标、高程值、回波数、回波强度等信息。

通常,获得的原始点云数据由于扫描过程中碰到低空飞行物、建筑物或者因仪器本身存在误差而产生噪声点,因此,首先需要对 LiDAR 数据进行噪点删除。然后使用“点云魔方(Point Cloud Magic, PCM)”对预处理后的点云数据进行分类,分离出地面点和非地面点。用反距离插值法将提取的地面点和非地面点栅格化,分别插值生成数字高程模型(Digital Elevation Model, DEM)和数字表面模型(Digital Surface Model, DSM)。最后,基于 DEM



审图号:GS(2019)3266号

图1 研究区及样地位置

Fig. 1 Location of study area and sample plots

的高程实现所有点云数据高程的正规化。

### 2.3 无人机高光谱数据获取及处理

高光谱数据的获取时间与LiDAR数据相同,高光谱影像由无人机遥感平台搭载微型高光谱成像光谱仪(Micro-HyperSpec)航拍获得。高光谱数据有346个波段,数量较多且连续,光谱范围在380—1 020 nm,光谱分辨率优于5 nm,空间分辨率为0.185 m。高光谱数据的处理过程在ENVI 5.3(ES-RI, Inc.)软件中完成,包括影像的大气校正、几何校正及镶嵌。首先通过大气校正得到光谱反射率,然后结合LiDAR数据生成的DSM,手动选择相对应的地面控制点实现高光谱影像的几何校正,最后对影像进行无缝镶嵌。光谱反射率的提取在ArcGIS软件中完成,根据实测数据提供的41块玉米样地的中心坐标及LiDAR数据采样半径提取样本内光谱反射率的平均值。

### 2.4 LiDAR数据的特征变量

已有的研究发现,采样尺寸、高度阈值及点密度对植被参数的反演精度具有一定的影响<sup>[21]</sup>。因此,本研究开展了不同采样尺寸、高度阈值及点密度对LAI反演精度影响的研究并确定三者最优值。对每一块样地而言选取的半径范围在2—7 m,增加量为0.5 m;高度阈值范围在0.00—0.65 m,增加量为0.05 m;点密度范围在0.25—420 points/m<sup>2</sup>,总共有87个不同的点密度,基于此对LiDAR数据重采

样,并利用高程正规化后的点云数据提取一系列LiDAR特征变量,本研究利用的LiDAR特征变量为常用的离散回波变量包括最大高度( $H_{\max}$ )、平均高度( $H_{\text{mean}}$ )、高度百分位数( $H_{40\text{th}}$ 、 $H_{50\text{th}}$ 、 $H_{60\text{th}}$ 、 $H_{70\text{th}}$ 、 $H_{75\text{th}}$ 、 $H_{80\text{th}}$ 、 $H_{90\text{th}}$ 、 $H_{95\text{th}}$ 、 $H_{99\text{th}}$ )、覆盖度( $f_{\text{cover}}$ )等20个变量,然后选择反演LAI的最优变量。所有的特征变量及具体描述如表1所示。

表1 LiDAR特征变量

Table 1 LiDAR metrics

变量	描述
$H_{\text{mean}}$	平均高度
$H_{\max}$	最大高度
$H_{\text{sd}}$	高度标准差
$H_{\text{var}}$	高度方差
$H_{\text{cv}}$	变异系数
$H_{\text{MADmode}}$	高度总体模态的绝对偏差的中位数
$H_{\text{skew}}$	高度偏度
$H_{(40\text{th}, 50\text{th}, 60\text{th}, 70\text{th}, 75\text{th}, 80\text{th}, 90\text{th}, 95\text{th}, 99\text{th})}$	百分位高度
Canopy relief ratio (CRR)	冠层起伏比
$f_{\text{cover}}$	覆盖度
$H_{\text{SQRT mean SQ}}(H_{\text{ss}})$	高度平方根平均值的平方
$H_{\text{CURT mean CUBE}}(H_{\text{cc}})$	高度立方根平均值的立方

注: $H_{(40\text{th}, 50\text{th}, 60\text{th}, 70\text{th}, 75\text{th}, 80\text{th}, 90\text{th}, 95\text{th}, 99\text{th})}$ 分别表示40%、50%、60%、70%、75%、80%、90%、95%、99%百分位高度。

### 2.5 植被指数的提取

根据地理环境、植被类型不同,对不同种类的植被指数进行筛选,并利用不同波段组合的方式计



算植被指数。同时,与多光谱遥感数据相比,高光谱数据具有高光谱分辨率的特性,红边波段数量较多,并且以往的研究表明,红边指数对 LAI 较为敏感,两者间的相关性大<sup>[22]</sup>,因此,研究提取了 9 种红边指数和普通植被指数参与 LAI 的反演,包括 RNDVI、CIrededge、MSR、VOG2、REP、NVI、EVI2、SRI、NDVI。不同植被指数计算公式及来源见表 2。

## 2.6 建模方法及模型评价指标

基于比尔定律(Beer-Lambert)<sup>[25]</sup>,利用单一变

量覆盖度来估算不同采样尺寸、高度阈值及点密度下的 LAI,通过将 LAI 实测值与预测值进行拟合,分析不同采样尺寸、高度阈值及点密度对 LAI 反演结果的影响,并确定 LiDAR 点云数据的最优采样尺寸、高度阈值及点密度。采用偏最小二乘回归算法和随机森林回归算法,分别利用 LiDAR 变量(基于最优采样尺寸、高度阈值及点密度下的 LiDAR 数据进行提取)、植被指数、联合 LiDAR 变量和植被指数建立玉米叶面积指数的预测模型。

表 2 植被指数及计算公式

Table 2 Vegetation indexes and calculation equation

植被指数	计算公式	来源
红边归一化植被指数(Red Edge Normalized Difference Vegetation Index,RNDVI)	$RNDVI = (R_{760.6} - R_{701.4}) / (R_{760.6} + R_{701.4})$	[10]
红边模型植被指数(CIrededge)	$CIrededge = R_{749.5} / R_{719.9} - 1$	[12]
改进红边比值植被指数(Modified Red Edge Simple Ratio Index MSR)	$MSR = (R_{749.5} - R_{444.3}) / (R_{705.1} + R_{444.3})$	[14]
红边指数 2(Vogelmann Red Edge Index VOG2)	$VOG2 = (R_{734.7} - R_{747.7}) / (R_{714.4} + R_{725.5})$	[23]
红边位置(Red Edge Position Index REP)	$REP = 705 + 35 * (0.5 * (R_{782.8} + R_{664.4}) - R_{705.1}) / (R_{740.3} - R_{705.1})$	[24]
新型植被指数(New Vegetation Index NVI)	$NVI = (R_{777.3} - R_{747.7}) / R_{673.7}$	[14]
增强型植被指数 2(Enhanced Vegetation Index EVI2)	$EVI2 = 2.5 * (R_{867.9} - R_{636.7}) / (R_{867.9} + 2.4 * R_{636.7} + 1)$	[10]
简单比值植被指数(Simple Ratio Index SRI)	$SRI = R_{799.5} / R_{670.0}$	[12]
归一化植被指数(Normalized Difference Vegetation Index,NDVI)	$NDVI = (R_{799.5} - R_{670.0}) / (R_{799.5} + R_{670.0})$	[12]

PLSR 集成了主成分分析、典型相关分析和线性回归分析的优点,可以同时实现回归建模、简化数据结构和分析两组变量间的相关性,解决变量之间多重共线性问题。RF 是集成机器学习的一种,基于决策树分类集成算法,通过对数据集的列变量和行变量观测行随机化,生成多个分类树,最终分类树结果进行汇总,这一方法能很好地降低噪声,防止过拟合,并对共线性数据不敏感。两种方法建立回归模型分别使用 SIMAC-P11.5 软件和 Python 语言实现。研究采用留一交叉验证方法(Leave-One-Out Cross-Validation, LOOCV)来评估模型的预测精度,所有的 41 个样本都用于建模,在样本较少的情况下,这一方法能够有效地评价模型的泛化能力。模型评价指标选用决定系数  $R^2$ ,均方根误差 RMSE, $R^2$  越接近 1, RMSE 越接近 0 说明模型拟合效果越好,反演精度越高。

## 3 结果分析

### 3.1 LiDAR 数据的采样尺寸、高度阈值及点密度对 LAI 反演精度的影响

基于原始点云密度(420 points/m<sup>2</sup>)探讨了最佳采样尺寸和高度阈值。采样尺寸和高度阈值对 LAI 反演精度的影响如表 3 和图 2 所示,研究结果表明,

随着采样尺寸和高度阈值的增加, LAI 的反演精度也不断发生变化,精度最高时的采样半径有两个,分别为 5.5 m 和 6.0 m,为了使采样面积更接近于野外实测样地面积,该研究选择 5.5 m 作为最优采样尺寸。利用最优采样尺寸 5.5 m 得到反演 LAI 的最优高度阈值为 0.55 m。基于最优采样尺寸和高度阈值,研究了激光雷达点密度对 LAI 反演结果的影响,如图 3 所示, LAI 反演的最佳激光雷达点密度为 18 points/m<sup>2</sup>,此时的  $R^2$  高达 0.884,与原始点密度( $R^2=0.866$ , RMSE=1.581)相比,玉米 LAI 的反演精度  $R^2$  提高了 2.08%, RMSE 降低了 0.89%。因此,本研究的最优采样尺寸、高度阈值和点云密度分别为 5.5 m、0.55 m 和 18 points/m<sup>2</sup>。

### 3.2 基于偏最小二乘回归算法反演 LAI

#### 3.2.1 变量重要性

在偏最小二乘模型中,投影重要性指标(Variable Importance in the Projection, VIP)用来表示每一个预测变量对因变量的重要性以及对预测模型的贡献程度,如图 4(a)—4(c)所示,该研究分别对 LiDAR 变量、植被指数、联合 LiDAR 变量和植被指数的 VIP 值进行计算,并且选用 VIP 值大于 1 的自变量参与预测模型的构建。图 4(a)表明 VIP 值大于 1 的变量包括从 CRR 到 H<sub>60th</sub> 共 11 个数,图 4(b)表

表 3 不同采样尺寸和高度阈值下 LAI 预测值与实测值的回归分析

Table 3 Regression analysis of LAI predicted value and measured value under different sampling sizes and height thresholds

高度阈值/m	采样尺寸/m										
	2.0	2.5	3.0	3.5	4.0	4.5	5.0	5.5	6.0	6.5	7.0
	$R^2$	$R^2$	$R^2$	$R^2$	$R^2$	$R^2$	$R^2$	$R^2$	$R^2$	$R^2$	$R^2$
0.00	0.707	0.754	0.763	0.786	0.800	0.815	0.820	0.814	0.809	0.792	0.774
0.05	0.710	0.737	0.764	0.787	0.801	0.817	0.826	0.825	0.822	0.809	0.795
0.01	0.724	0.747	0.773	0.796	0.811	0.828	0.838	0.841	0.840	0.830	0.817
0.15	0.731	0.752	0.779	0.804	0.818	0.835	0.845	0.850	0.850	0.841	0.830
0.20	0.739	0.759	0.784	0.809	0.823	0.839	0.850	0.855	0.855	0.847	0.836
0.25	0.742	0.761	0.788	0.812	0.827	0.843	0.853	0.858	0.858	0.850	0.840
0.30	0.744	0.763	0.790	0.815	0.829	0.845	0.854	0.860	0.860	0.852	0.842
0.35	0.746	0.765	0.791	0.816	0.830	0.846	0.856	0.861	0.862	0.854	0.844
0.40	0.748	0.767	0.793	0.818	0.832	0.848	0.857	0.863	0.863	0.856	0.846
0.45	0.749	0.767	0.793	0.818	0.833	0.849	0.858	0.864	0.864	0.858	0.848
0.50	0.749	0.768	0.794	0.819	0.834	0.850	0.859	0.865	0.866	0.860	0.850
0.55	0.749	0.768	0.794	0.820	0.835	0.851	0.860	0.866	0.866	0.861	0.852
0.60	0.750	0.768	0.795	0.820	0.834	0.851	0.860	0.866	0.867	0.862	0.854
0.65	0.749	0.767	0.793	0.819	0.834	0.850	0.859	0.866	0.866	0.863	0.855




图 2 基于最优采样尺寸的高度阈值对玉米 LAI 预测精度的影响

Fig.2 Influence of height threshold based on optimal sampling size on LAI prediction accuracy of maize

明只有 REP、VOG2、NVI 3 个植被指数的重要性超过了 1。图 4(c)中仅有一个植被指数 NVI 的 VIP 值超过了 1,其余自变量全为 LiDAR 变量,虽然植被指数的个数较少,但是相对于一些其他的 LiDAR 变量( $H_{90th}$ 、 $H_{95th}$ 、 $H_{99th}$ 、 $H_{max}$ )而言,个别的植被指数还是具有更高的贡献。

### 3.2.2 LAI 反演结果

本研究基于最优采样尺寸、高度阈值、点密度提取了 LiDAR 变量,分别利用 LiDAR 变量、植被指数、联合 LiDAR 变量和植被指数建立了玉米 LAI 预测模型,基于偏最小二乘回归算法获得的 LAI 反演精度如表 4 所示。图 5(a)—5(c)分别为基于 Li-




图 3 基于最优采样尺寸和高度阈值的点密度对玉米 LAI 预测精度的影响

Fig.3 Influence of point density based on optimal sampling size and height threshold on LAI prediction accuracy of Maize

DAR 变量、植被指数、组合变量的玉米 LAI 预测值与实测值的散点图,实线为拟合线。利用 LiDAR 变量获得的 LAI 预测值与实测值的验证结果( $R^2=0.874$ )高于植被指数( $R^2=0.741$ ),而联合 LiDAR 变量和植被指数构建模型的预测精度最高,拟合效果最好( $R^2=0.885$ ),与前两种预测模型相比, $R^2$ 分别提高了 1.26% 和 19.4%,RMSE 分别降低了 4.10% 和 33.04%。

### 3.3 基于随机森林回归算法反演 LAI

#### 3.3.1 变量重要性

随机森林回归算法也具有自动计算每一个预




图4 利用偏最小二乘回归模型估算LAI的变量重要性排序

Fig.4 The importance ranking of variables for estimating LAI by partial least squares regression mode




图5 基于偏最小二乘回归模型的LAI预测值与实测值散点图

Fig.5 Scatter plots of LAI predicted value and measured value based on partial least squares regression model

测变量对因变量的重要性并进行自动排序的功能。本研究基于随机森林回归算法,使用LiDAR变量、植被指数、联合LiDAR变量和植被指数反演玉米LAI的变量重要性排序如图6所示。如图6(a)—6(c)表明反演LAI最重要的变量分别是Hskew、REP、Hskew,并且图6(c)表明重要性排名前十的变量均为LiDAR变量,与植被指数相比,LiDAR变量在玉米叶面积指数反演过程中更具有优势。

### 3.3.2 LAI反演结果

表4、图7分别为基于随机森林回归算法利用LiDAR变量、植被指数、联合LiDAR变量和植被指数的拟合结果与散点图。利用3种不同的变量构建的预测模型得到的 $R^2$ 均在0.85以上,模型拟合效果较好。其中使用两种数据源融合构建预测模型反演玉米LAI的精度最高,误差最小( $R^2=0.950$ ,  $RMSE=0.203$ ),其次是利用LiDAR变量构建模型的预测精度( $R^2=0.942$ ,  $RMSE=0.222$ ),基于植被




图6 利用随机森林回归模型估算LAI的变量重要性排序

Fig.6 The importance ranking of variables for estimating LAI by random forest regression model

指数的LAI反演精度最低( $R^2=0.861$ ,  $RMSE=0.338$ )。与单独使用LiDAR变量相比,加入植被指数后的 $R^2$ 仅提高了0.85%,这表明从高光谱影像中提取的植被指数对LAI的反演精度有一定提高作用,但贡献较小,反演效果改善不明显。

表4 利用不同预测模型和变量的LAI预测精度分析

Table 4 Accuracy analysis of LAI prediction using different prediction models and metrics

变量	偏最小二乘回归		随机森林回归	
	$R^2$	RMSE	$R^2$	RMSE
LiDAR 变量	0.874	0.317	0.942	0.222
植被指数	0.741	0.454	0.861	0.338
LiDAR 变量+植被指数	0.885	0.304	0.950	0.203

## 4 讨论

### 4.1 LiDAR数据的采样尺寸、高度阈值及点密度对LAI反演精度的影响

表3列出了不同采样尺寸和高度阈值下的LAI反演精度,在任意高度阈值下,随着采样尺寸的不断扩大,反演精度也在不断变化,采样尺寸为5.5 m

时的 $R^2$ 达到最高。以高度阈值0.20 m为例,与采样尺寸2.0 m时的预测精度( $R^2=0.739$ )相比,最高反演精度的 $R^2$ 提高了15.70%。最优采样尺寸的反演精度高于最大和最小采样尺寸的反演精度,主要原因是采样尺寸过大所获得的结果与野外实测样地的LAI不符,而采样尺寸过小则导致构建DEM的地面点不足,从而降低LAI的反演精度。因此,选择合适的采样尺寸对提高LAI的反演精度尤为重要。同样,基于最优采样半径5.5 m,估算了高度阈值在0.00—0.65 m内的LAI。图2表明随着高度阈值的递增,玉米LAI反演精度不断发生变化,当高度阈值为0.55 m时 $R^2$ 达到最高0.866,继续增加高度阈值对LAI反演精度的改善效果甚微,因为采用较高的高度阈值会导致过多的植被点划分为地面点导致反演的LAI缺乏真实性,所以确定0.55 m为最优高度阈值,并且与最低(高度阈值为0.00 m)反演精度( $R^2=0.814$ )相比,最优高度阈值的 $R^2$ 提高了6.39%。结果表明不同的高度阈值会对LAI的反演精度产生影响从而获得不一样的结果。因此,为了






图7 基于随机森林回归模型的LAI预测值和实测值的散点图

Fig.7 Scatter plots of LAI predicted value and measured value based on random forest regression model

提高LAI的反演精度,需要确定最优的高度阈值。实验的最优采样尺寸和高度阈值分别为5.5 m和0.55 m,虽然与Nie等<sup>[26]</sup>的最优值(采样尺寸为3.5 m,高度阈值为0.10 m)不一样,但是Nie等<sup>[26]</sup>在玉米LAI反演研究中发现,不同地理条件下的样地生长的植被存在差异,因此,在开展研究之前要根据具体的激光雷达数据确定采样尺寸和高度阈值。

基于最优采样尺寸和高度阈值探索LAI反演精度最高时的点密度。随着LiDAR点密度的递增,LAI反演精度的评价指标 $R^2$ 和RMSE也不断发生变化。当点密度在0.5 points/m<sup>2</sup>以下时,LAI的反演精度发生了较大的变化,这说明此时的点密度过低不足以准确估算玉米LAI。点密度在0.5—6 points/m<sup>2</sup>区间内的反演精度变化虽然比较缓和但可以观察到明显的波动。6 points/m<sup>2</sup>之后,点密度不断增加对LAI的反演精度几乎没有影响, $R^2$ 的变化也很微小,LAI反演精度最高时的点密度为18 points/m<sup>2</sup>,比最低反演精度( $R^2=0.139$ )提高了535.97%,改善效果显著,与原始点密度(最高点密度420 points/m<sup>2</sup>)相比, $R^2$ 提高了2.07%。精度最高时的点密度不仅比原始点密度低约23倍,而且有更高的精度,说明低密度的LiDAR点云数据能够实现LAI的精确估算,而单一的增加点密度对提高LAI反演精度的作用不大,Roussel等<sup>[27]</sup>在森林冠层高度的估算中也有类似的研究发现。另外,基于无人机遥感平台的数据采集过程中,为获得高密度的点云数据往往会降低飞机的飞行高度同时使飞行路径重叠<sup>[28]</sup>,这都会造成采集成本的增加,并且单一的增加点密度有时候并不能提高植被参数的反演精度,因此确定一个合适的点密度对提高植被结构参数反演精度以及降低研究成本具有举足轻重的作用。

#### 4.2 基于PLS和RF建模方法的变量重要性

利用偏最小二乘回归算法的重要性排序结果表明,CRR、REP、CRR分别是这3个反演模型中贡献度最大的变量,其中使用单独的LiDAR变量、联合LiDAR变量与植被指数得到的最重要的指标均为CRR,而由图6(a)和图6(c)可知利用随机森林回归算法建模也有相似的结果,两者贡献度最大的变量为 $H_{skew}$ 。两种建模方法中同一变量的重要性出现排序差异以及两种方法的变量重要性评分存在量级上的差异。主要是PLSR与RF原理不同,PLSR作为一种统计方法是基于PLSR权重的加权平方和计算每一个变量的重要性,而RF机器学习方法是评估每个特征在每棵决策树上做的贡献,进行平均值计算,最后比较不同特征之间的贡献大小。将未参与决策树建立的袋外数据(Out-Of-Bag, OOB)的错误率作为评估指标来衡量贡献值大小,错误率越大,说明特征的重要程度越高。整体而言,基于这两种方法构建模型得到的高重要性变量均不同于已有的研究,Li等<sup>[29]</sup>联合机载激光雷达与高分一号卫星影像反演玉米LAI的研究中,根据以往的经验选择了有代表性的指标(LPI、 $H_{mean}$ 、 $H_{var}$ 、NDVI)参与建模,利用这些变量得到的LAI反演精度( $R^2=0.83$ )低于该研究,但精度差异较小,这一差异主要与地理环境、遥感数据类型相关。在利用组合变量建立的两种模型中,原本单独数据源的重要性发生变化,重新进行排列后的前10位预测变量全部为LiDAR变量,植被指数对预测LAI的贡献较小,这表明激光雷达点云数据在LAI反演方面的优势明显高于高光谱数据。Shi等<sup>[30]</sup>在利用两种数据源反演其他植被参数的研究中也发现了类似的发现。

#### 4.3 基于PLS和RF建模方法的LAI预测结果

该研究利用不同的建模方法,探索LiDAR数



据、高光谱影像以及联合LiDAR数据和高光谱影像反演玉米LAI的潜力。借助偏最小二乘回归算法建立了三种预测模型,模型预测精度如表4所示,融合LiDAR变量与植被指数构建模型的预测精度最高( $R^2=0.885$ ,  $RMSE=0.304$ ),LiDAR变量次之( $R^2=0.874$ ,  $RMSE=0.317$ ),利用植被指数反演LAI的精度最低( $R^2=0.741$ ,  $RMSE=0.454$ ),该研究结果与牛玉洁等<sup>[31]</sup>的发现相似,他们的结论表明联合LiDAR变量构建模型的预测效果优于单独使用植被指数。表4同样展示了利用随机森林回归算法构建的3种预测模型的 $R^2$ 分别为0.942、0.861、0.950, $RMSE$ 分别为0.222、0.338、0.203,与使用单一数据源建立的模型相比,联合LiDAR变量和植被指数的模型拟合效果最好,而且LAI的预测值与实测值的误差最小。

无论是偏最小二乘回归算法还是随机森林回归算法,单独使用LiDAR变量反演LAI的精度均高于植被指数,主要是在LAI较高的区域,植被指数易趋于饱和导致LAI的估算存在偏差,而激光雷达作为一种主动遥感技术很好地解决了这一问题,在LAI提取方面具有广泛的应用,同时研究发现二者结合进一步改善了仅利用LiDAR变量的建模效果,提高了LAI的预测精度,其原因在于植被指数的加入弥补了激光雷达数据缺少地物光谱信息的不足,实现了两种数据源的优势互补。同样,研究结果仍表明尽管结合植被指数后的模型预测效果有所提升,但是这种变化比较微弱,提升幅度分别为1.26%和0.85%,植被指数对提高LAI反演精度的贡献较小,其原因是LiDAR变量已经与LAI存在很强的相关性,额外的植被指数对最终的反演结果影响较小,而与选取的植被指数无关。以往的研究中也有相关报道,Luo等<sup>[20]</sup>发现结合激光雷达伪波形与高光谱数据反演LAI的精度改进效果并不明显,Phua等<sup>[32]</sup>联合两种数据源反演生物量的研究也有类似的发现。但整体而言,联合无人机激光雷达和高光谱数据在LAI反演方面还是具有很大的潜力,特别是在植被稀疏,LAI较低的区域。

两种算法的建模精度和拟合效果存在差异,与偏最小二乘回归算法相比,基于随机森林回归算法利用LiDAR变量、植被指数、联合LiDAR变量和植被指数建立LAI预测模型得到的反演精度 $R^2$ 分别提高了7.78%、16.19%、7.34%, $RMSE$ 分别降低了29.97%、25.55%、33.22%,对比这两种算法的反演

精度,结果表明随机森林预测模型的估算能力更好。这一结果可能与参与建模的预测变量相关,本研究中使用的LiDAR变量和植被指数本身存在较强的共线性,虽然偏最小二乘回归算法能够解决自变量之间存在的多重共线性的问题,但是这种能力是有限的,当共线性程度超过了模型的降维能力,模型的预测能力就会减弱,而随机森林回归算法对共线性并不敏感,不容易产生过拟合,并且不需要进行降维<sup>[33]</sup>。因此,基于随机森林回归算法,利用LiDAR变量与植被指数结合构建的模型为最优预测模型。

## 5 结 论

该研究表明无人机激光雷达与高光谱数据能够可靠地反演玉米LAI,具体结论如下:

(1)采样尺寸、高度阈值以及点密度都会影响LAI的反演精度,因此根据植被类型、地理环境以及激光雷达点云数据的不同确定最优采样尺寸、高度阈值以及点密度能够有效地改善反演效果,本研究确定的最优采样尺寸、高度阈值、点密度分别为5.5 m、0.55 m、18 points/m<sup>2</sup>。

(2)研究了一系列点密度对LAI反演精度的影响,发现LAI的反演精度没有随点密度递增而上升,而是到达某一高度后,预测精度的波动变得和缓,往后不断增大点密度对改进预测效果几乎没有作用。原始点密度(最高点密度)没有获得最高估测精度,而降低的点密度能使LAI反演精度达到最高。

(3)利用激光雷达点云数据建立的模型预测精度均优于高光谱数据,激光雷达数据在LAI反演方面更有优势,而两种数据源结合的LAI反演精度最高,并且该研究表明随机森林回归算法建立的3种预测模型的精度都优于偏最小二乘回归算法。

总之,联合无人机激光雷达和高光谱数据可以提高玉米LAI的反演精度,融合两种数据源反演植被参数具有一定的应用潜力。然而该研究表明联合两种数据反演LAI的精度并没有明显提高,主要原因在于单一的LiDAR数据已经获得了高精度的LAI。因此,在激光雷达植被参数研究过程中要根据研究区域大小、经费以及精度要求确定是否有必要获取多种数据源以提高植被参数的反演精度。

## 参考文献(References):

- [1] Liu L H, Ouyang W, Liu H B, *et al.* Potential of paddy drain-

- age optimization to water and food security in China[J]. Resources, Conservation and Recycling, 2021, 171: 105624-105633. DOI: 10.1016/j.resconrec. 2021.105624.
- [2] Yamashita M, Toyoda H, Tanaka Y. Light environment and LAI monitoring in rice community by ground- and UAV-based remote sensing[J]. ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020, XLIII-B3-2020: 1085-1089. DOI: 10.5194/isprs-archives-XLIII-B3-2020-1085-2020.
- [3] Wang Pengxin, Qi Xuan, Li Li, *et al.* Estimation of maize yield based on random forest regression[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(7): 237-245.[王鹏新, 齐璇, 李俐, 等. 基于随机森林回归的玉米单产估测[J]. 农业机械学报, 2019, 50(7): 237-245.]
- [4] Hou Jiyu, Zhou Yanlian, Liu Yang. Spatial and temporal differences of GPP simulated by different satellite-derived LAI in China[J]. Remote Sensing Technology and Application, 2020, 35(5): 1015-1027.[侯吉宇, 周艳莲, 刘洋. 不同叶面积指数遥感数据模拟中国总初级生产力的时空差异[J]. 遥感技术与应用, 2020, 35(5): 1015-1027.]
- [5] Tan Yibo, Zhao Zhonghui. The main methods for determining leaf area index[J]. Forest Inventory and Planning, 2008(3): 45-48.[谭一波, 赵仲辉. 叶面积指数的主要测定方法[J]. 林业调查规划, 2008(3): 45-48.]
- [6] Liu Jiangang, Zhao Chunjiang, Yang Guijun, *et al.* Review of field-based phenotyping by unmanned aerial vehicle remote sensing platform[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 32(24): 98-106.[刘建刚, 赵春江, 杨贵军, 等. 无人机遥感解析田间作物表型信息研究进展[J]. 农业工程学报, 2016, 32(24): 98-106.]
- [7] Wang Y, Fang H L. Estimation of LAI with the LiDAR technology: A review[J]. Remote Sensing, 2020, 12(20): 3457-3484. DOI: 10.3390/rs12203457.
- [8] Zhou L F, Gu X H, Cheng S, *et al.* Analysis of plant height changes of lodged maize using UAV-LiDAR data[J]. Agriculture, 2020, 10(5): 146-159. DOI: 10.3390/agriculture10050146.
- [9] Harkel J T, Bartholomeus H, Kooistra L. Biomass and crop height estimation of different crops using UAV-based LiDAR[J]. Remote Sensing, 2019, 12(1): 17-34. DOI: 10.3390/rs12010017.
- [10] Cheng Xue, He Bingyan, Huang Yaohuan, *et al.* Estimation of corn leaf area index based on UAV hyperspectral image[J]. Remote Sensing Technology and Application, 2019, 34(4): 775-784.[程雪, 贺炳彦, 黄耀欢, 等. 基于无人机高光谱数据的玉米叶面积指数估算[J]. 遥感技术与应用, 2019, 34(4): 775-784.]
- [11] Liu K, Shen X, Cao L, *et al.* Estimating forest structural attributes using UAV-LiDAR data in Ginkgo plantations[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 146: 465-482. DOI: 10.1016/j.isprsjprs.2018.11.001.
- [12] Liu Yang, Feng Haikuan, Huang Jue, *et al.* Estimation of potato plant height and above-ground biomass based on UAV hyperspectral images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(2): 188-198.[刘杨, 冯海宽, 黄珏, 等. 基于无人机高光谱影像的马铃薯株高和地上生物量估算[J]. 农业机械学报, 2021, 52(2): 188-198.]
- [13] Xie Jingkai, Wang Fumin, Wang Feilong, *et al.* Correction of the soil adjusted factors of vegetation indices for monitoring rice Leaf Area Index[J]. Remote Sensing Technology and Application, 2018, 33(2): 342-350.[谢京凯, 王福民, 王飞龙, 等. 面向水稻LAI监测的植被指数土壤调节参数修正[J]. 遥感技术与应用, 2018, 33(2): 342-350.]
- [14] He Jia, Liu Bingfeng, Li Jun. Monitoring model of leaf area index of winter wheat based on hyperspectral reflectance at different growth stages[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 30(24): 141-150.[贺佳, 刘冰峰, 李军. 不同生育时期冬小麦叶面积指数高光谱遥感监测模型[J]. 农业工程学报, 2014, 30(24): 141-150.]
- [15] Hmida S B, Kallel A, Gastellu-Etchegorry J P, *et al.* Crop biophysical properties estimation based on LiDAR full-waveform inversion using the DART RTM[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(11): 4853-4868. DOI: 10.1109/JSTARS.2017.2763242.
- [16] Pang Yong, Li Zengyuan, Chen Erxue, *et al.* LiDAR remote sensing technology and Its application in forestry[J]. Scientia Sinicae, 2005, 41(3): 129-136.[庞勇, 李增元, 陈尔学, 等. 激光雷达技术及其在林业上的应用[J]. 林业科学, 2005, 41(3): 129-136.]
- [17] Jimenez-Berni J A, Deery D M, Pablo R L, *et al.* High throughput determination of plant height, ground cover, and above-ground biomass in wheat with LiDAR[J]. Frontiers in Plant Science, 2018, 9: 237-254. DOI: 10.3389/fpls.2018.00237.
- [18] Su Wei, Zhan Junge, Zhang Mingzheng, *et al.* Estimation method of crop leaf area index based on airborne LiDAR data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(3): 272-277.[苏伟, 展郡鸽, 张明政,

- 等. 基于机载 LiDAR 数据的农作物叶面积指数估算方法研究[J]. 农业机械学报, 2016, 47(3): 272-277.]
- [19] Lei L, Qiu C X, Li Z H, *et al.* Effect of leaf occlusion on leaf area index inversion of maize using UAV - LiDAR data[J]. Remote Sensing, 2019, 11(9): 1067-1081. DOI: 10.3390/rs11091067.
- [20] Luo S Z, Wang C, Xi X H, *et al.* Combining hyperspectral imagery and LiDAR pseudo-waveform for predicting crop LAI, canopy height and above-ground biomass[J]. Ecological Indicators, 2019, 102: 801-812. DOI: 10.1016/j.ecolind. 2019. 03.011.
- [21] Tian Luo, Qu Yonghua, Korhonen Lauri, *et al.* Estimation of forest leaf area index based on spectrally corrected airborne LiDAR pulse penetration index by intensity of point cloud[J]. Journal of Remote Sensing, 2020, 24(12): 1450-1463.[田罗, 屈永华, Korhonen Lauri, 等. 考虑目标光谱差异的机载离散激光雷达叶面积指数反演[J]. 遥感学报, 2020, 24(12): 1450-1463.]
- [22] Guo Yunkai, Liu Yuling, Xu Min, *et al.* Modeling and analysis of red edge index estimated by leaf area index in road vegetation[J]. Science of Surveying and Mapping, 2021, 46(1): 93-98.[郭云开, 刘雨玲, 许敏, 等. 植被叶面积指数估算的红边指数建模分析[J]. 测绘科学, 2021, 46(1): 93-98.]
- [23] Vogelmann J E, Rock B N, Moss D M. Red edge spectral measurements from sugar maple leaves[J]. International Journal of Remote Sensing, 1993, 14(8): 1563-1575. DOI: 10.1080/01431169308953986.
- [24] Dawson T P, Curran P J. Technical note a new technique for interpolating the reflectance red edge position[J]. International Journal of Remote Sensing, 1998, 19(11): 2133-2139. DOI: 10.1080/014311698214910.
- [25] Richardson J J, Moskal L M, Kim S H. Modeling approaches to estimate effective leaf area index from aerial discrete-return LiDAR[J]. Agricultural & Forest Meteorology, 2009, 149(6-7): 1152-1160. DOI: 10.1016/j.agrformet.2009.02.007.
- [26] Nie S, Wang C, Dong P L, *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. DOI: 10.1080/2150704X.2015.1111536.
- [27] Roussel J R, Caspersen J, Béland M, *et al.* Removing bias from LiDAR-based estimates of canopy height: Accounting for the effects of pulse density and footprint size[J]. Remote Sensing of Environment, 2017, 198: 1-16. DOI: 10.1016/j.rse.2017.05.032.
- [28] Jakubowski M K, Guo Q H, Kelly M. Tradeoffs between LiDAR pulse density and forest measurement accuracy[J]. Remote Sensing of Environment, 2013, 130: 245-253. DOI: 10.1016/j.rse.2012.11.024.
- [29] Li W, Niu Z, Wang C, *et al.* Combined use of airborne LiDAR and satellite GF-1 data to estimate Leaf Area Index, height, and aboveground biomass of maize during peak growing season[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(9): 4489-4501. DOI: 10.1109/JSTARS.2015.2496358.
- [30] Shi J C, Wang C, Xi X H, *et al.* Retrieving FPAR of maize canopy using artificial neural networks with airborne LiDAR and hyperspectral data[J]. Remote Sensing Letters, 2020, 11(11): 1002-1011. DOI: 10.1080/2150704X.2020.1807647.
- [31] Niu Yujie, Li Xiaopeng, Zhang Jiabao, *et al.* Inversion of leaf area index in winter wheat by merging UAV LiDAR with multispectral remote sensing data[J]. Acta Pedologica Sinica, 2020, 59(1): 161-171.[牛玉洁, 李晓鹏, 张佳宝, 等. 融合无人机载激光雷达与多光谱遥感数据的冬小麦叶面积指数反演[J]. 土壤学报, 2020, 59(1): 161-171.]
- [32] Phua M H, Johari S A, Wong O C, *et al.* Synergistic use of Landsat-8 OLI image and airborne LiDAR data for above-ground biomass estimation in tropical lowland rainforests[J]. Forest Ecology and Management, 2017, 406: 163-171. DOI: 10.1016/j.foreco.2017.10.007.
- [33] Shi Botai, Chang Qingrui, Cui Xiaotao, *et al.* LAI estimation of winter wheat based on Sentinel-2 multispectral data and machine learning algorithm[J]. Journal of Triticeae Crops, 2021, 41(6): 752-761.[史博太, 常庆瑞, 崔小涛, 等. 基于 Sentinel-2 多光谱数据和机器学习算法的冬小麦 LAI 遥感估算[J]. 麦类作物学报, 2021, 41(6): 752-761.]



## Combining UAV LiDAR and Hyperspectral Data for Retrieving Maize Leaf Area Index

Zhang Yaqian<sup>1</sup>, Luo Shezhou<sup>1</sup>, Wang Cheng<sup>2</sup>, Xi Xiaohuan<sup>2</sup>, Nie Sheng<sup>2</sup>,  
Li Dong<sup>2</sup>, Li Guanghui<sup>3</sup>

(1.College of Resources and Environment, Fujian Agriculture and Forestry University,  
Fuzhou 350002, China;

2.Key Laboratory of Digital Earth Science, Aerospace Information Research Institute, Chinese Academy of  
Sciences, Beijing 100094, China;

3.Aerogeophysical and Remote Sensing Center of Henan Province, Zhengzhou 450053, China)

**Abstract:** Leaf Area Index (LAI) is an important index for crop growth monitoring and yield estimation. Accurate and efficient LAI retrieval plays an important role in the macroscopic management of farmland economy. This study explored the potential of combining UAV LiDAR and hyperspectral data to retrieve maize leaf area index, studied the effects of different sampling size, height threshold and point density of LiDAR data on LAI inversion accuracy, and determined the optimal values of the three parameters. In this study, LiDAR variables and vegetation indices were extracted from resampled LiDAR data and hyperspectral imagery respectively. Then, based on Partial Least Squares Regression (PLSR) and Random Forest (RF) regression, LiDAR variables, vegetation indices, combined LiDAR variables and vegetation indices were used to construct prediction models, and the optimal prediction model for LAI inversion of maize was determined. The results show that the optimal sampling size, height threshold and point density of maize LAI inversion are 5.5 m, 0.55 m and 18 points/m<sup>2</sup> respectively. We found that the highest point density (420 points/m<sup>2</sup>) did not obtain the optimal LAI inversion accuracy of maize. Therefore, it is not reliable to improve the inversion accuracy of LAI by increasing point density alone. The LAI inversion accuracies based on LiDAR variables (PLSR:  $R^2 = 0.874$ , RMSE = 0.317; RF:  $R^2 = 0.942$ , RMSE = 0.222) were higher than those based on vegetation indices (PLSR:  $R^2 = 0.741$ , RMSE = 0.454; RF:  $R^2 = 0.861$ , RMSE = 0.338), and the inversion accuracies of the prediction model constructed using combination variable (PLSR:  $R^2 = 0.885$ , RMSE = 0.304; RF:  $R^2 = 0.950$ , RMSE = 0.203) were better than using single variable, in which the random forest regression model established by using combined LiDAR variables and vegetation indices is the best prediction model. Therefore, the fusion of the two data sources has a certain potential in improving the accuracy of vegetation LAI retrieval.

**Key words:** UAV-LiDAR; Hyperspectral; Leaf Area Index(LAI); Maize; LiDAR point density