

# 结合无人机光谱与纹理特征和覆盖度的水稻叶面积指数估算

杭艳红<sup>1</sup>, 苏欢<sup>1</sup>, 于滋洋<sup>2</sup>, 刘焕军<sup>1,2\*</sup>, 官海翔<sup>1</sup>, 孔繁昌<sup>1</sup>

(1. 东北农业大学公共管理与法学院, 哈尔滨 150030; 2. 中国科学院东北地理与农业生态研究所, 长春 130012)

**摘要:** 为了探究无人机多指标构建叶面积指数 (Leaf Area Index, LAI) 估算模型的能力, 该研究通过不同纹理组合方式优选纹理指数, 分别以光谱特征、纹理指数和作物覆盖度作为输入量建立一元线性模型, 3 类指标结合构建多元逐步回归和人工神经网络模型, 分析多指标结合估算 LAI 的精度。结果表明: 新的纹理指数能够明显提高纹理特征值与 LAI 的相关性, 近红外波段均值与蓝波段均值的差值较近红外波段均值提高了 13.54%; 将绿度归一化植被指数 (Green Normalized Difference Vegetation Index, GNDVI)、差值纹理指数和作物覆盖度结合来估算水稻 LAI 的精度最好, 多指标结合的多元逐步回归模型的决定系数为 0.866, 调整后决定系数为 0.816, 均方根误差为 0.308, 人工神经网络模型结果再次验证这一结论。该研究成果可为基于无人机平台估算作物结构参数提供理论依据, 并为其他作物 LAI 估算提供借鉴。

**关键词:** 无人机; 叶面积指数; 多光谱; 覆盖度; 纹理指数; 水稻

doi: 10.11975/j.issn.1002-6819.2021.09.008

中图分类号: S127

文献标志码: A

文章编号: 1002-6819(2021)-09-0064-08

杭艳红, 苏欢, 于滋洋, 等. 结合无人机光谱与纹理特征和覆盖度的水稻叶面积指数估算[J]. 农业工程学报, 2021, 37(9): 64-71. doi: 10.11975/j.issn.1002-6819.2021.09.008 http://www.tcsae.org

Hang Yanhong, Su Huan, Yu Ziyang, et al. Estimation of rice leaf area index combining UAV spectrum, texture features and vegetation coverage[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2021, 37(9): 64-71. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2021.09.008 http://www.tcsae.org

## 0 引言

水稻作为重要的粮食作物, 其生产关系到中国的粮食安全, 而叶面积指数作为水稻生长的一项重要参数, 能够提供水稻生长过程的动态信息, 与地上部生物量的积累和产量形成密切相关<sup>[1]</sup>, 是评价作物长势及指导田间管理的重要指标。目前叶面积指数 (Leaf Area Index, LAI) 地面测量方法包括直接测量法和间接测量法。直接测量法精度相对精确, 但费时费力, 且离散的地面测量点不利于大规模的监测农作物长势<sup>[1]</sup>, 测量过程中还会对作物造成一定破坏; 间接测量法是采用测量参数或光学仪器进行测量, 常用的有 LAI-2000 植被冠层分析仪、Sunscan 密度计等<sup>[2]</sup>。卫星遥感具有大面积同步观测的特点, 被广泛应用于 LAI 估算中, 但受分辨率和重访周期的限制, 相比卫星遥感, 无人机遥感不仅具有更高的时间和空间分辨率, 而且能够快速获得田块尺度作物的空间变异信息, 能够准确反映地块内部的长势差异。

近年来, 国内外学者针对植被指数估算 LAI 展开了大量研究, 在机理上已经被证明植被指数能够较好地估算作物 LAI<sup>[3]</sup>。根据绿度归一化植被指数 (Green Normalized Difference Vegetation Index, GNDVI) 和 LAI

的线性关系建立模型<sup>[4]</sup>, 但植被指数在 LAI 较大时会出现饱和和现象<sup>[5]</sup>, 在估算 LAI 时存在一定局限性。近些年基于无人机影像, 结合光谱特征和纹理特征估算作物生长状况的研究逐渐增多, 研究发现将植被指数与纹理特征融合, 可以有效提高生物量<sup>[6]</sup>、叶绿素含量<sup>[7]</sup>和氮营养指数<sup>[8]</sup>的估算精度, 国内外结合光谱信息和纹理特征估算生物量<sup>[9-10]</sup>的研究有很多, 但在估算作物 LAI 方面研究较少, 且以往的研究多是直接将众多纹理特征值参与到模型中, 缺少对纹理特征值的优化。同时, 有研究发现在植被指数的基础上引入作物覆盖度也可用于估算 LAI<sup>[11]</sup>, 但以往的研究多是在传统基于植被指数的 LAI 估算方法的基础上引进纹理特征或作物覆盖度等指标, 缺少对光谱特征、纹理指数和作物覆盖度等指标共同估算 LAI 能力的研究。

综合以上研究存在的问题, 该研究旨在利用具有高空间分辨率的无人机多光谱影像, 通过对水稻冠层纹理特征进行组合运算来建立新的纹理指数, 以期提高纹理特征值与水稻 LAI 的相关性, 结合光谱特征、纹理指数和作物覆盖度, 构建多指标结合的水稻 LAI 估算模型, 以期提高水稻 LAI 估算精度。

## 1 材料与方法

### 1.1 试验设计

水稻田间试验于 2018 年 7—8 月在黑龙江省五常市试验站 (44°44'N, 127°12'E) 进行 (图 1)。研究区属温带大陆性季风气候, 平均海拔约为 450 m, 年平均降雨量在 500~800 mm, 年平均气温 3~4 °C。采用随机区组设计进行了稻田试验。施肥处理采用移栽后施一次基肥, 分蘖期和抽穗期之前进行两次追肥的施肥方式。基肥、

收稿日期: 2021-01-14 修订日期: 2021-04-24

基金项目: 国家自然科学基金 (4167012020); 东北农业大学“学术骨干”项目 (54932612)


作者简介: 杭艳红, 副教授, 硕士生导师, 研究方向为土地资源利用。

Email: 13936391994@163.com

\*通信作者: 刘焕军, 教授, 博士生导师, 研究方向为农业遥感。

Email: liuhuanjun@neigae.ac.cn

分蘖肥和穗肥的施肥比例为 5:2:3。施肥品种为磷酸氢二铵、尿素和硫酸钾，磷酸氢二铵的含  $P_2O_5$  量为 46%，含 N 量为 17%，尿素的含 N 量为 46%，硫酸钾的含  $K_2O$  量为 50%（以上含量均为质量分数）。试验包括 5 种氮肥处理，每种施氮处理有 3 次重复试验，共 30 个样区，每个样区面积为  $50\text{ m}^2$ ，包括五优稻 4 号和松粳 6 号两个水稻品种。



注：N0、N1、N2、N3、N4 分别表示 0、79.1、90.5、102.3 和  $115\text{ kg}\cdot\text{hm}^{-2}$  5 个氮肥水平。  
Note: N0, N1, N2, N3, N4 represent five nitrogen fertilizer levels of 0, 79.1, 90.5, 102.3 and  $115\text{ kg}\cdot\text{hm}^{-2}$ , respectively.

图 1 研究区地理位置及地面采样区

Fig.1 Geographical location of study area and the ground sampling areas

1.2 数据来源

1.2.1 地面数据获取

该研究于 2018 年水稻拔节期（7 月 22 日）和抽穗期（8 月 8 日）2 个关键生育期分别采集了水稻 LAI 数据，共有 60 个样本。LAI-2000 测量的结果为总叶面积指数（Plant Area Index, PAI），实际上是包含 LAI 和木质面积指数（Woody Area Index, WAI），对于树林冠层，WAI 的影响较大，不可用 PAI 直接替代 LAI<sup>[12]</sup>；而水稻属于水平均匀植被，WAI 的影响较小，LAI-2000 在连续、均质的冠层测量时具有较好的结果<sup>[13]</sup>。因此采用美国 LI-COR 公司生产的 LAI-2000 植物冠层分析仪测量 LAI，测量时间为上午 08:00—10:00。该研究在每个样区设置一个植被覆盖较均一且具有区域代表性的地点作为采样区域，每个生长阶段在不同的采样区进行 LAI 测定，每个采样区选择 3 处测量并记录 LAI 值，取 3 次测量平均值作为该样区的 LAI 值。每个采样区先测量冠层上方的 1 个天空光，然后测量冠层下方的 4 个测试目标值，样方的 LAI 值由 LAI-2000 自带的软件计算。为了避免太阳光线直射带来的测量误差值，数据采集选择上午 10:00 之前直射光较弱的时段，测量时操作员背对阳光，并且在天气晴朗时使用遮盖帽进行遮光处理。

1.2.2 多光谱数据获取与处理

该研究采用大疆 M600 Pro 六旋翼高性能无人机搭载

MicaSense RedEdge™3 多光谱相机。大疆 M600 Pro 六旋翼高性能无人机最大飞行承载质量为 6 kg，可承受最大风速 8 m/s，可在  $-10\sim40^{\circ}\text{C}$  的环境中工作，续航时间为 25~35 min。MicaSense RedEdge™3 多光谱相机拥有蓝、绿、红、红边、近红外 5 个波段（表 1），配有光强传感器、全球定位系统（Global Positioning System, GPS）模块和白板<sup>[14]</sup>。MicaSense RedEdge™3 是美国 MicaSense 公司生成的一款专业的多光谱相机，能够同时捕获 5 个不连续的光谱带，光谱采集范围为 400~900 nm，拥有 5 个通道。MicaSense RedEdge™3 在执行任务时，能够达到每秒一次捕捉。飞行过程中，光强传感器可用于校正太阳光线变化对影像造成的影响；GPS 模块同时记录每张影像的位置信息；白板具有固定的反射率信息，可用来对影像反射率进行校正。

表 1 多光谱相机波段  
Table 1 Multispectral camera bands

波段号 Band number	波段名称 Band name	中心波长 Center wavelength/nm	带宽 Bandwidth/nm	白板反射率 Whiteboard reflectivity
B1	蓝 Blue	475	20	0.71
B2	绿 Green	560	20	0.73
B3	红 Red	668	10	0.72
B4	红边 Red edge	717	10	0.66
B5	近红外 Near IR	840	40	0.71

数据采集时间为 2018 年 7 月 22 日和 2018 年 8 月 8 日，天气晴朗无云，风速小于 3 级，适合无人机飞行，选择的无人机遥感平台对地观测时间为 8:00—10:00。为确保影像的完整性和准确性，地面站设置航向重叠为 80%，旁向重叠为 75%，主航线角度  $90^{\circ}$ ，飞行高度设定为 110 m，图像空间分辨率为 7 cm。

为去除姿态角度异常和由大气传输等因素导致的成像问题，对采集到的无人机影像先进行筛选；对筛选后的影像进行数据预处理，将影像导入 Pix4D mapper 软件，调节处理参数，采用自动生成的连接点与无人机内置的定位定向系统（Position and Orientation System, POS）数据进行空三运算，生成三维点云数据；最后对影像进行仿射变换，得到该研究区的无人机正射多光谱影像<sup>[15]</sup>。

1.3 多光谱影像特征提取

1.3.1 植被指数计算

植被指数（Vegetation Index, VI）能够简单、有效地度量地表植被状况，植被指数是反映植被在可见光、近红外波段反射与土壤背景之间差异的指标，各植被指数能够在一定条件下用来定量表明植被的生长状况。归一化差值植被指数（Normalized Difference Vegetation Index, NDVI）对绿色植被表现敏感，常被用于 LAI 估测，但在植被覆盖度较高时呈现饱和状态，对植被检测灵敏度下降；GNDVI 将绿波段代替 NDVI 中的红波段，对叶绿素 a 的敏感度更高；差值植被指数（Difference Vegetation Index, DVI）、修正三角植被指数（Modified Triangular Vegetation Index 2, MTVI<sub>2</sub>）和优化土壤调节植被指数（Optimized Soil-adjusted Vegetation Index,

OSAVI) 能够降低土壤和环境背景等影响因子的影响; 红边叶绿素指数 (Red-edge Chlorophyll Index,  $CI_{RE}$ ) 与植被叶片的叶绿素浓度具有高度相关性, 能够反应植被生长状况。该研究选取 6 个与 LAI 相关的植被指数对水稻 LAI 进行估算 (表 2)。

表 2 植被指数及公式  
Table 2 Vegetation indexes and formulas

植被指数 Vegetation index	计算公式 Formula	参考来源 Reference
归一化差值植被指数 Normalized difference vegetation index	$NDVI = (R_{NIR} - R_R) / (R_{NIR} + R_R)$	[16]
修正三角植被指数 Modified triangular vegetation index 2	$MTVI2 = \frac{1.5[1.2(R_{NIR} - R_G) - 2.5(R_R - R_G)]}{\sqrt{(2R_{NIR} + 1)^2 - (6R_{NIR} - 5\sqrt{R_R}) - 0.5}}$	[17]
差值植被指数 Difference vegetation index	$DVI = R_{NIR} - R_R$	[18]
优化土壤调节 植被指数 Optimized soil-adjusted vegetation index	$OSAVI = \frac{(1 + 0.16) \times (R_{NIR} - R_G)}{R_{NIR} + R_G + 0.16}$	[19]
绿度归一化植被指数 Green normalized difference vegetation index	$GNDVI = (R_{NIR} - R_G) / (R_{NIR} + R_G)$	[20]
红边叶绿素指数 Red-edge chlorophyll index	$CI_{RE} = R_{NIR} / R_{RE} - 1$	[21]

注: 表中的  $R_G$ ,  $R_R$ ,  $R_{RE}$ ,  $R_{NIR}$  分别表示绿、红、红边、近红外波段。

Note: The subscripts  $R_G$ ,  $R_R$ ,  $R_{RE}$ ,  $R_{NIR}$  in the table respectively represent green, red, red edge, near-infrared bands.

### 1.3.2 纹理特征提取

在几种纹理算法中, 常用灰度共生矩阵 (Gray-Level Co-occurrence Matrix, GLCM) 测试纹理分析。在进行辐射校正后, 使用 ENVI 5.3 软件计算 8 类基于 GLCM 的纹理特征值, 包括均值 (Mean, mean)、方差 (Variance, var)、协同性 (Homogeneity, hom)、对比度 (Contrast, con)、相异性 (Dissimilarity, dis)、信息熵 (Entropy, ent)、二阶矩 (Second Moment, sm) 和相关性 (Correlation, corr) [22], 共 40 个纹理特征值。无人机影像的分辨率为 7 cm, 大多数窗口大小涉及土壤背景和水稻植株, 因此在该研究中, 纹理分析选取最小的 3×3 窗口进行分析。该研究区的水稻田垄向接近 90°, 因此, 在纹理分析时方向选取 90°。

该研究所用 3 种纹理指数 (Texture Index, TI) 定义分别为: 归一化差值纹理指数 (Normalized Difference Texture Index, NDTI) [23], 差值纹理指数 (Difference Texture Index, DTI), 比值纹理指数 (Ratio Texture Index, RTI)。构造了 5 个波段 (475、560、668、717 和 840 nm) 与 8 类基于 GLCM 的纹理特征值相结合的所有可能的两种纹理测量组合, 以探索它们的估算能力。利用 Matlab 软件实现对纹理指数 NDTI, DTI, RTI 的运算, 并计算出不同纹理指数与 LAI 之间的相关性。

NDTI, DTI, RTI 定义分别如下:

$$NDTI = (T_1 - T_2) / (T_1 + T_2) \quad (1)$$

$$DTI = T_1 - T_2 \quad (2)$$

$$RTI = T_1 / T_2 \quad (3)$$

式中  $T_1$  和  $T_2$  为随机任意波段的纹理特征值。

### 1.3.3 作物覆盖度提取

作物覆盖度 (Crop Coverage, CC) 是指植被在地面的垂直投影面积占总面积的百分比。由于作物覆盖度与 LAI 之间具有显著的相关性, 本文将提取作物覆盖度并将其输入水稻 LAI 估算模型中。本文采用像元二分法的思路, 使用 ArcGIS 输出无人机影像的灰度图, 再对灰度图应用 OTSU 算法, 寻找令植被与非植被类间方差最大的灰度阈值, 将非植被区域灰度值置零, 提取出植被区域的像元, 进而计算出该影像的作物覆盖度 [24]。

### 1.4 模型构建

该研究中, 选取拔节孕穗期和抽穗期试验的数据进行模型构建, 总样本量 60, 采用 K-折交叉验证法作为验证方法。选取 3 种方法建立模型, 分别为一元线性模型、多元逐步回归模型、人工神经网络模型。采用决定系数 (Determination coefficient,  $R^2$ )、调整后决定系数 (Adjusted determination coefficient,  $R^2_{adj}$ ) 和均方根误差 (Root Mean Square Error, RMSE) 评价模型的精度。一般来说,  $R^2$  和  $R^2_{adj}$  越高, 表明模型越稳定; RMSE 越低, 表明模型精度越高。

#### 1.4.1 K-折交叉验证

本文采取 K-折交叉验证的方式建模并评估模型精度。K-折交叉验证是应用最广泛的泛化误差估计方法之一, 对于检验模型具有普适性, 适用于样本集不大的情况 [7], 将数据集均分为 K-份, 每次训练取其中一份作为验证集, 剩余部分作为测试集, 重复 K 次, 完成一次交叉验证 [25]。K-折交叉验证保证了数据集中的每个数据都参与了建模与验证, 能够让模型更好地学习到数据中的特征; 同时 K-折交叉验证建模的精度是 K 次训练精度的均值, 能更好地估计模型的泛化误差。该研究采取 5-折交叉验证, 即训练集样本个数为 48, 测试集样本数为 12, 训练 5 次。

#### 1.4.2 线性模型

植被指数法是光学遥感估算植被 LAI 常用的经验方法。分别选用以上 6 种植被指数、纹理指数和作物覆盖度与 LAI 进行相关性分析, 并建立一元线性模型估算 LAI。选择植被指数、纹理指数和作物覆盖度等因子作为变量, 构建多元线性逐步回归模型估算 LAI。

#### 1.4.3 人工神经网络模型

基于误差反向传播 (Back Propagation, BP) 的人工神经网络是应用最广泛的神经网络, 它的基本思想是利用梯度下降法, 逐层求出目标函数对各神经元权值的偏导数, 作为权值更新的依据, 使模型学习达到期望的性能 [26]。本文使用的神经网络主要包含三部分, 输入层、隐藏层和输出层, 其中输入层不参与运算, 隐藏层和输出层为全连接层。本文以均方误差为目标函数, 学习率为 0.01 建立了一个包含 5 层隐藏层的人工神经网络模型。选择植被指数、纹理指数和作物覆盖度等因子作为变量, 输入到人工神经网络模型估算 LAI。

## 2 结果与分析

### 2.1 不同指标与 LAI 的相关性分析

植被指数是根据地物光谱反射率的差异进行运算，以此突出图像中植被的特征。对选取的 6 个植被指数和 LAI 的相关性进行分析。结果显示，植被指数与 LAI 之间的相关性均达到极显著水平 ( $P < 0.01$ )，其中与 LAI 相关性由大到小依次是：OSAVI、MTVI2、DVI、GNDVI、NDVI、CI<sub>RE</sub>，相关系数依次是 0.763、0.761、0.731、0.718、0.667、0.606。对 1.3.3 中提取的作物覆盖度与实测水稻 LAI 进行相关性分析，结果显示显著相关且相关系数为 0.785。

单一纹理特征与 LAI 的相关性分析结果 (表 3) 显示多数纹理特征与 LAI 的相关性并不高，只有少部分纹理特征显示出与 LAI 存在较高的相关性，其中 LAI 与近红外波段的纹理特征均值的相关性最高，相关系数为 0.731。

由于纹理特征值与 LAI 的相关性较低，因此构建了由不同纹理特征值组成的指数 NDTI, DTI, RTI 以提高纹理特征值对 LAI 的估测能力。结果如图 2 显示，通过对纹理特征进行组合运算，在整体上明显提高了纹理特征值与 LAI 的相关性，3 种指数的均值组合与 LAI 具有较高的相关性。优选出每种组合运算纹理指数中与 LAI

相关性最高的纹理指数，按相关性由高到低依次是近红外波段和蓝波段均值的差值 DTI ( $\text{mean}_5, \text{mean}_1$ )、近红外波段均值与绿波段信息熵的比值 RTI ( $\text{mean}_5, \text{ent}_2$ )、近红外波段均值与绿波段信息熵的归一化值 NDTI ( $\text{mean}_5, \text{ent}_2$ )，相关系数依次是 0.830、0.798、0.791。结果证明对纹理特征进行组合运算，能够明显提高纹理特征值与 LAI 的相关性，近红外波段均值与蓝波段均值的差值较近红外波段均值提高了 13.54%。


表 3 单一纹理特征和 LAI 的相关性分析

Table 3 Correlation analysis between single texture feature and leaf area index

纹理特征 Texture feature	相关系数 Correlation coefficient $r$				
	B1	B2	B3	B4	B5
对比度 Contrast (con)	-0.245	0.125	-0.451**	-0.505**	-0.359**
相关性 Correlation (corr)	-0.350**	-0.203	-0.049	-0.073	-0.164
相异性 Dissimilarity (dis)	-0.238	0.084	-0.424**	-0.511**	-0.398**
信息熵 Entropy (ent)	-0.358**	-0.139	-0.395**	-0.399**	-0.402**
协同性 Homogeneity (hom)	0.220	-0.015	0.386**	0.475**	0.438**
均值 Mean (mean)	0.055	0.302**	-0.176	0.377**	0.731**
二阶矩 Second moment (sm)	0.293*	0.171	0.324*	0.387**	0.411**
方差 Variance (var)	-0.431**	0.017	-0.523**	-0.526**	-0.406**

注：\*和\*\*分别表示相关性在 0.05 和 0.01 水平下达到显著。

Note: \* and \*\* mean significantly correlation at 0.05 and 0.01 level, respectively.



注：NDTI、DTI、RTI 分别为归一化差值纹理指数、差值纹理指数、比值纹理指数，由任意两个纹理特征值计算得到。图中任意点表示该点横纵坐标对应的 2 个纹理特征值经归一化、比值、差值运算后的纹理指数与 LAI 的相关系数。

Note: NDTI, DTI, RTI are normalized difference texture index, difference texture index, ratio texture index. Any point in the figure represents the correlation coefficient between the texture index, which is obtained by normalization, ratio, and difference of the two texture feature values corresponding to the horizontal and vertical coordinates of the point, and the LAI.

图 2 LAI 与纹理指数的相关系数

Fig.2 Correlation coefficient between LAI and texture index

### 2.2 一元线性模型估算 LAI

根据多光谱影像提取的输入量，建立单一输入量与试验区实测 LAI 的一元线性模型，由结果 (表 4) 可知，6 种遥感植被指数与 LAI 建立的一元线性模型中，GNDVI 模型  $R^2$  最高，达 0.603， $R^2_{\text{adj}}$  为 0.563，RMSE 为 0.541；优选纹理指数与 LAI 建立的一元线性模型中，DTI ( $\text{mean}_5, \text{mean}_1$ ) 模型  $R^2$  最高，达 0.668， $R^2_{\text{adj}}$  为 0.635，RMSE 为 0.447；作物覆盖度与 LAI 建立的一元线性模型  $R^2$  为 0.633， $R^2_{\text{adj}}$  为 0.596，RMSE 为 0.516。对比不同单一输入量与试验区实测 LAI 的一元线性模型结果发现，精度由高到低依次为 DTI ( $\text{mean}_5, \text{mean}_1$ )、作物覆盖度、GNDVI。

### 2.3 多元逐步回归模型估算 LAI

本研究先将 3 类输入量分别两两类组合放入多元逐步回归模型中构建 LAI 估算模型，再将 3 类输入量全部放入多元逐步回归模型中构建 LAI 估算模型，对比不同输入量组合的模型精度并进行评价。由结果 (表 4 和表 5) 可知，结合植被指数和纹理指数的多元逐步回归模型 ( $R^2=0.728$ ， $R^2_{\text{adj}}=0.668$ ，RMSE=0.421) 明显优于单一植被指数模型 ( $R^2=0.603$ ， $R^2_{\text{adj}}=0.563$ ，RMSE=0.541)，结合植被指数、纹理指数和作物覆盖度共同估算 LAI 模型 ( $R^2=0.866$ ， $R^2_{\text{adj}}=0.816$ ，RMSE=0.308) 精度最高，优于所有单一输入量和任意两类输入量组合。因此，结合植被指数、纹理指数和作物覆盖度共同估算 LAI 可以被认



为是一种能够有效改善 LAI 估算精度的方法。

为了对多元逐步回归模型筛选出的变量进行进一步分析,揭示各输入因子对模型的影响,本文引入“贡献度”这一指标。此处的贡献度为偏相关系数的绝对值与模型中个因子的偏相关系数绝对值总和之比<sup>[7]</sup>。如表 5 所

示,基于多指标结合的 LAI 估算模型中,作物覆盖度和纹理指数 DTI (mean<sub>5</sub>, mean<sub>1</sub>) 对模型的贡献度均很大,植被指数 GNDVI 贡献度相对较小。作物覆盖度、DTI (mean<sub>5</sub>, mean<sub>1</sub>)、GNDVI 对模型的贡献度分别为 40.413%、35.507%、24.08%。

表 4 LAI 的一元线性估算模型与精度评价  
Table 4 Unary linear estimation model and precision evaluation of LAI

模型输入量 Model input	模型公式 Model formula	R <sup>2</sup>	R <sup>2</sup> <sub>adj</sub>	RMSE
DVI	LAI=3.072DVI-0.3252	0.481	0.429	0.562
OSAVI	LAI=15.598OSAVI-10.663	0.587	0.546	0.510
MTVI2	LAI=13.732MTVI2-10.402	0.474	0.421	0.586
GNDVI	LAI=17.097GNDVI-8.2074	0.603	0.563	0.541
CI <sub>RE</sub>	LAI=0.1419CI <sub>RE</sub> +1.3164	0.429	0.372	0.628
NDVI	LAI=17.778NDVI-12.156	0.494	0.443	0.588
DTI (mean <sub>5</sub> ,mean <sub>1</sub> )	LAI=0.1055DTI (mean <sub>5</sub> ,mean <sub>1</sub> )+0.139	0.668	0.635	0.447
RTI (mean <sub>5</sub> ,ent <sub>2</sub> )	LAI=0.1932RTI (mean <sub>5</sub> ,ent <sub>2</sub> )-0.6012	0.616	0.578	0.476
NDTI (mean <sub>5</sub> ,ent <sub>2</sub> )	LAI=35.487NDTI (mean <sub>5</sub> ,ent <sub>2</sub> )-28.847	0.621	0.583	0.483
CC	LAI=57.727CC-45.402	0.633	0.596	0.516

注:表中的下标 1、2、3、4、5 分别表示蓝、绿、红、红边、近红外波段。DTI (mean<sub>5</sub>,mean<sub>1</sub>) 表示近红外波段与蓝波段均值之差,RTI (mean<sub>5</sub>,ent<sub>2</sub>) 表示近红外波段均值与绿波段信息熵的比值,NDTI (mean<sub>5</sub>,ent<sub>2</sub>) 表示近红外波段均值与绿波段信息熵的归一化值。CC 为作物覆盖度。  
Note: The subscripts 1, 2, 3, 4, 5 in the table respectively represent blue, green, red, red edge, near-infrared bands. DTI(mean<sub>5</sub>,mean<sub>1</sub>) represents the mean difference between near-infrared and blue, RTI (mean<sub>5</sub>, ent<sub>2</sub>) represents the ratio of the mean of the near-infrared band to the entropy of the green band, NDTI (mean<sub>5</sub>, ent<sub>2</sub>) represents the normalized value of the mean of the near-infrared band and the entropy of the green band. CC is the crop coverage.

表 5 LAI 的多元线性逐步回归估算模型与精度评价  
Table 5 Multiple linear stepwise regression estimation model and accuracy evaluation of LAI

模型输入量 Model input	模型公式 Model formula	因子 Factor	偏相关系数 Partial correlation coefficient	贡献度 Contribution%	R <sup>2</sup>	R <sup>2</sup> <sub>adj</sub>	RMSE
VIs、CC	LAI=36.197CC+10.342OSAVI-36.393	OSAVI	0.696	48.502	0.829	0.791	0.327
		CC	0.739	51.498			
VIs、TIs	LAI=5.983GNDVI+0.091DTI(mean <sub>5</sub> ,mean <sub>1</sub> )-3.376	GNDVI	0.313	31.331	0.728	0.668	0.421
		DTI(mean <sub>5</sub> ,mean <sub>1</sub> )	0.686	68.669			
CC、TIs	LAI=27.282CC+0.071DTI(mean <sub>5</sub> ,mean <sub>1</sub> )-21.806	CC	0.652	48.620	0.807	0.764	0.334
		DTI(mean <sub>5</sub> ,mean <sub>1</sub> )	0.689	51.380			
VIs、CC、TIs	LAI=5.697GNDVI+27.913CC+0.057 DTI(mean <sub>5</sub> ,mean <sub>1</sub> )-25.687	GNDVI	0.373	24.080	0.866	0.816	0.308
		DTI(mean <sub>5</sub> ,mean <sub>1</sub> )	0.550	35.507			
		CC	0.626	40.413			

注: VIs 为植被指数, TIs 为纹理指数。DTI (mean<sub>5</sub>, mean<sub>1</sub>) 表示近红外波段均值与蓝波段均值的差值。  
Note: VIs is the vegetation index and TIs is the texture index. DTI (mean<sub>5</sub>, mean<sub>1</sub>) represents the difference between the mean value of the near-infrared band and the mean value of the blue band.

2.4 人工神经网络模型估算 LAI

为了排除模型对文章结论的影响,证明本文结论的普适性,本文使用人工神经网络对结论进行进一步验证。本文将 3 类输入量依次放入人工神经网络模型中构建 LAI 估算模型,对比模型精度。结果如表 6 所示,将植被指数与纹理指数结合构建 LAI 模型,发现模型精度 (R<sup>2</sup>=0.76, R<sup>2</sup><sub>adj</sub>=0.707, RMSE=0.365) 较单一植被指数构建的 LAI 模型 (R<sup>2</sup>=0.654, R<sup>2</sup><sub>adj</sub>=0.619, RMSE=0.431) 精度得到明显提高;将植被指数、纹理指数和作物覆盖度共同构建 LAI 模型,发现模型 (R<sup>2</sup>=0.836, R<sup>2</sup><sub>adj</sub>=0.775, RMSE=0.286) 精度最高。基于人工神经网络模型估算 LAI 得到的结论与基于多元逐步回归模型估算 LAI 得到的结论一致,再次验证结合植被指数、纹理指数和作物覆盖度共同估算 LAI,是一种能够有效改善 LAI 估算精度的方法。

表 6 LAI 的人工神经网络预测模型与精度评价  
Table 6 Artificial neural network forecast model and accuracy evaluation of LAI

模型输入量 Model input	R <sup>2</sup>	R <sup>2</sup> <sub>adj</sub>	RMSE
VIs	0.654	0.619	0.431
CC	0.649	0.614	0.446
TIs	0.728	0.701	0.391
VI、CC	0.797	0.752	0.335
VI、TI	0.760	0.707	0.365
CC、TI	0.801	0.757	0.323
VI、CC、TI	0.836	0.775	0.286

3 讨 论

在以往的研究中,多是利用光谱信息与地面实测数据来对 LAI 进行估算,但仅仅利用植被指数进行 LAI 估

算存在一定的局限性。因此,从无人机影像中提取纹理特征和作物覆盖度来提高 LAI 估算精度具有重要意义。

纹理是物体表面的内在特性,不依赖于颜色和亮度而变化,能够抑制同谱异物和同物异谱现象的发生<sup>[27]</sup>。大多数纹理特征值与 LAI 的相关性较弱,该研究对纹理特征值进行组合运算得到新的纹理指数,有效提高了纹理特征估算 LAI 的性能。纹理归一化能够降低土壤背景、太阳角和传感器视角影响<sup>[28]</sup>;纹理比值可以放大地物波段特征间的细微差别,降低影像中地形、阴影等带来的影响,突出地物特征;纹理差值能够去除影像中的相同背景<sup>[27]</sup>,遥感图像中由阴影产生的影响在纹理差值图像中表现得不明显,因此纹理信息与光谱特征的结合在一定程度上削弱了阴影对变化检测产生的影响。

该研究利用多元逐步回归模型,将植被指数、纹理指数和作物覆盖度结合起来建立水稻 LAI 估算模型。结合植被指数和纹理指数的多元逐步回归模型 ( $R^2=0.728$ ,  $R^2_{\text{adj}}=0.668$ ,  $\text{RMSE}=0.421$ ) 明显优于单一植被指数模型 ( $R^2=0.603$ ,  $R^2_{\text{adj}}=0.563$ ,  $\text{RMSE}=0.541$ ), 结合植被指数、纹理指数和作物覆盖度共同估算 LAI ( $R^2=0.866$ ,  $R^2_{\text{adj}}=0.816$ ,  $\text{RMSE}=0.308$ ) 精度最高, 优于所有单一输入量和任意两类输入量组合。这主要是因为多指标结合模型综合了植光谱特征、纹理特征和作物覆盖度对 LAI 估算的共同贡献。其中 GNDVI 对叶绿素 a 较为敏感, 绿叶的叶绿素在光照条件下发生光合作用产生植物干物质积累, 使叶面积增大<sup>[29]</sup>; 水稻的覆盖度随着 LAI 的增加而增加, 覆盖度可以直接反映从俯视图提取的 LAI 值<sup>[30]</sup>; 纹理指数 DTI ( $\text{mean}_s, \text{mean}_t$ ) 提供了作物的空间特征, 一定程度上弥补了光谱信息的不足, 其中纹理测量均值包含移动窗口中的目标和背景的平均值, 可以平滑图像, 使背景的干扰最小化, 又因为绿色植被在蓝波段对光强吸收, 在近红外波段由于冠层结构的漫反射导致近红外处反射率较大<sup>[31]</sup>, 近红外波段与蓝波段的差值能增强植被对光吸收和反射的差异, 因此能够更好反映绿色植被冠层结构。光谱特征、纹理特征和作物覆盖度的结合为 LAI 估算模型提供了更多的信息。该研究尚存在部分局限性, 考虑到影响水稻 LAI 的因素不止光谱特征、纹理特征和作物覆盖度, 还需要综合考虑原始波段、叶绿素、土壤背景以及影像质量等因素的影响。

## 4 结 论

本文基于无人机多光谱影像, 对光谱特征、纹理特征和作物覆盖度估算水稻叶面积指数 (Leaf Area Index, LAI) 的能力进行了分析, 主要得到以下结论:

1) 对纹理特征进行组合运算, 能够明显提高纹理特征与 LAI 的相关性, 近红外波段均值与蓝波段均值的差值较近红外波段均值提高了 13.54%, 且归一化差值纹理指数、差值纹理指数、比值纹理指数的均值组合与 LAI 具有较高的相关性, 其中近红外波段和蓝波段均值的差值具有最高的相关性, 相关系数为 0.830。

2) 基于一元线性模型构建的水稻 LAI 估算模型的精

度由高到低为近红外波段和蓝波段均值的差值 (决定系数  $R^2=0.668$ , 调整后决定系数  $R^2_{\text{adj}}=0.635$ , 均方根误差  $\text{RMSE}=0.447$ )、作物覆盖度 ( $R^2=0.633$ ,  $R^2_{\text{adj}}=0.596$ ,  $\text{RMSE}=0.516$ )、绿度归一化植被指数 ( $R^2=0.603$ ,  $R^2_{\text{adj}}=0.563$ ,  $\text{RMSE}=0.541$ )。

3) 对比单一植被指数、纹理指数、作物覆盖度, 以及任意两类输入量的结合, 发现多特征结合估算水稻 LAI 的能力最强 ( $R^2=0.866$ ,  $R^2_{\text{adj}}=0.816$ ,  $\text{RMSE}=0.308$ ), 人工神经网络模型结果对本文结论进行进一步验证, 表明结合光谱特征、纹理指数、作物覆盖度共同估算 LAI 具有较好的精度, 为监测水稻生长状况提供一种可行的方法。

## [参 考 文 献]

- [1] 常好雪, 蔡晓斌, 陈晓玲, 等. 基于实测光谱的植被指数对水稻叶面积指数的响应特征分析[J]. 光谱学与光谱分析, 2018, 38(1): 205-211.  
Chang Haoxue, Cai Xiaobin, Chen Xiaoling, et al. Analysis of the response characteristics of vegetation index to rice leaf area index based on measured spectra[J]. Spectroscopy and Spectral Analysis, 2018, 38(1): 205-211. (in Chinese with English abstract)
- [2] 孙越, 顾祝军, 李栋梁. 无人机与卫星影像的叶面积指数遥感反演研究[J]. 测绘科学, 2021, 46(2): 106-112.  
Sun Yue, Gu Zhujun, Li Dongliang. Research on remote sensing retrieval of leaf area index from UAV and satellite images[J]. Science of Surveying and Mapping, 2021, 46(2): 106-112. (in Chinese with English abstract)
- [3] 邵国敏, 王亚杰, 韩文霆. 基于无人机多光谱遥感的夏玉米叶面积指数估算方法[J]. 智慧农业 (中英文), 2020, 2(3): 118-128.  
Shao Guomin, Wang Yajie, Han Wenting. Estimation method of summer corn leaf area index based on drone multispectral remote sensing[J]. Smart Agriculture (Chinese and English), 2020, 2(3): 118-128. (in Chinese with English abstract)
- [4] Hunt E R, Hively W D, Fujilcawa S J, et al. Acquisition of nir green- blue digital photographs from unmanned aircraft for crop monitoring[J]. Remote Sensing, 2010, 2: 290-305.
- [5] 宋开山, 张柏, 王宗明, 等. 基于人工神经网络的大豆叶面积高光谱反演研究[J]. 中国农业科学, 2006, 39(6): 1138-1145.  
Song Kaishan, Zhang Bai, Wang Zongming, et al. Research on hyperspectral retrieval of soybean leaf area based on artificial neural network[J]. Chinese Agricultural Sciences, 2006, 39(6): 1138-1145. (in Chinese with English abstract)
- [6] 刘畅, 杨贵军, 李振海, 等. 融合无人机光谱信息与纹理信息的冬小麦生物量估测[J]. 中国农业科学, 2018, 51(16): 3060-3073.  
Liu Chang, Yang Guijun, Li Zhenhai, et al. Winter wheat biomass estimation based on fusion of UAV spectral information and texture information[J]. Chinese Agricultural Sciences, 2018, 51(16): 3060-3073. (in Chinese with English abstract)
- [7] 陈鹏, 冯海宽, 李长春, 等. 无人机影像光谱和纹理融合信息估算马铃薯叶片叶绿素含量[J]. 农业工程学报, 2018, 34(10): 1-10.

- 2019, 35(11): 63-74.
- Chen Peng, Feng Haikuan, Li Changchun, et al. UAV image spectrum and texture fusion information to estimate potato leaf chlorophyll content[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(11): 63-74. (in Chinese with English abstract)
- [8] 杨福芹, 冯海宽, 肖天豪, 等. 融合无人机影像光谱与纹理特征的冬小麦氮营养指数估算[J]. 农业现代化研究, 2020, 41(4): 718-726.
- Yang Fuqin, Feng Haikuan, Xiao Tianhao, et al. Estimation of nitrogen nutrition index of winter wheat by combining UAV image spectral and texture features[J]. Research of Agricultural Modernization, 2020, 41(4): 718-726. (in Chinese with English abstract)
- [9] Yue J, Yang G J, Tian Q J, et al. Estimate of winter-wheat above-ground biomass based on UAV ultrahigh-ground-resolution image textures and vegetation indices[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019(150): 226-244.
- [10] Liu Y N, Liu S S, Li J, et al. Estimating biomass of winter oilseed rape using vegetation indices and texture metrics derived from UAV multispectral images[J]. Computers and Electronics in Agriculture, 2019, 26(6): 166-184.
- [11] 蔡雯洁, 沙晋明. 基于地理环境要素的叶面积指数遥感定量反演[J]. 亚热带资源与环境学报, 2019, 14(2): 55-64.
- Cai Wenjie, Sha Jinming. Remote sensing quantitative inversion of leaf area index based on geographical environment elements[J]. Journal of Subtropical Resources and Environment, 2019, 14(2): 55-64. (in Chinese with English abstract)
- [12] 阎广建, 胡容海, 罗京辉, 等. 叶面积指数间接测量方法[J]. 遥感学报, 2016, 20(5): 958-978.
- Yan Guangjian, Hu Ronghai, Luo Jinghui, et al. Indirect measurement method of leaf area index[J]. Journal of Remote Sensing, 2016, 20(5): 958-978. (in Chinese with English abstract)
- [13] Levy P E and Jarvis P G. Direct and indirect measurements of LAI in millet and fallow vegetation in HAPEX-sahel[J]. Agricultural and Forest Meteorology, 1999, 97(3): 199-212.
- [14] 张新乐, 官海翔, 刘焕军, 等. 基于无人机多光谱影像的完熟期玉米倒伏面积提取[J]. 农业工程学报, 2019, 35(19): 98-106.
- Zhang Xinle, Guan Haixiang, Liu Huanjun, et al. Extraction of corn lodging area at maturity stage based on UAV multispectral image[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(19): 98-106. (in Chinese with English abstract)
- [15] 孔繁昌, 刘焕军, 于滋洋, 等. 高寒地区粳稻穗颈瘟的无人机高光谱遥感识别[J]. 农业工程学报, 2020, 36(22): 68-75.
- Kong Fanchang, Liu Huanjun, Yu Ziyang, et al. UAV hyperspectral remote sensing identification of japonica rice panicle blast in alpine regions[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2020, 36(22): 68-75. (in Chinese with English abstract)
- [16] Tanaka S, Kawamura K, Maki M, et al. Spectral index for quantifying leaf area index of winter wheat by field hyperspectral measurements. A case study in Gifu prefecture, Central Japan[J]. Remote Sensing, 2015, 7(5): 5329-5346.
- [17] 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 Sensing of Environment, 2004, 90(3): 337-352.
- [18] 夏天, 吴文斌, 周清波, 等. 冬小麦叶面积指数高光谱遥感反演方法对比[J]. 农业工程学报, 2013, 29(3): 139-147.
- Xia Tian, Wu Wenbin, Zhou Qingbo, et al. Comparison of winter wheat leaf area index hyperspectral remote sensing inversion methods[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2013, 29(3): 139-147. (in Chinese with English abstract)
- [19] Liang L, Di L P, Zhang L P, et al. Estimation of crop LAI using hyperspectral vegetation indices and a hybrid inversion method[J]. Remote Sensing of Environment, 2015, 165: 123-134.
- [20] 王来刚, 徐建华, 贺佳, 等. 基于无人机遥感的玉米叶面积指数与产量估算[J]. 玉米科学, 2020, 28(6): 88-93.
- Wang Laigang, Xu Jianhua, He Jia, et al. Estimation of corn leaf area index and yield based on UAV remote sensing[J]. Maize Science, 2020, 28(6): 88-93. (in Chinese with English abstract)
- [21] Gitelson A A, Viña A, Ciganda V, et al. Remote estimation of canopy chlorophyll content in crops[J]. Geophysical Research Letters, 2005, 32(8): 1-4.
- [22] Boran J, Ping W, Shuo Z, et al. Detection of maize drought based on texture and morphological features[J]. Computers and Electronics in Agriculture, 2018, 151: 50-60.
- [23] Zheng H B, Cheng T, Zhou M, et al. Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery[J]. Precision Agriculture, 2019, 20(3): 611-629.
- [24] Huilcen Baca H A, Palomino Valdivia F d L, Ortiz Guizado J I, et al. Vegetation cover estimation from high-resolution satellite images based on chromatic characteristics and image processing[C]. 2020 39th International Conference of the Chilean Computer Science Society (SCCC), Coquimbo, Chile, 2020: 1-8.
- [25] Karal O. Performance comparison of different kernel functions in SVM for different k value in k-fold cross-validation[C]. 2020 Innovations in Intelligent Systems and Applications Conference (ASYU), Istanbul, Turkey, 2020: 1-5.
- [26] Chanda M, Biswas M. Plant disease identification and classification using Back-Propagation Neural Network with Particle Swarm Optimization[C]. 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI), Tirunelveli, India, 2019: 1029-1036.
- [27] 汪小钦, 江洪, 傅银贞. 森林叶面积指数遥感研究进展[J]. 福州大学学报: 自然科学版, 2009, 37(6): 822-828.
- Wang Xiaoqin, Jiang Hong, Fu Yinzen. Research progress

- in remote sensing of forest leaf area index[J]. Journal of Fuzhou University: Natural Science Edition, 2009, 37(6): 822-828. (in Chinese with English abstract)
- [28] Huete A R, Jackson R D, Post, D F. Spectral response of a plant canopy with different soil backgrounds[J]. Remote Sensing of Environment, 1985, 17(1): 37-53.
- [29] 赵英时. 遥感应用分析原理与方法[M]. 北京: 科学出版社, 2013.
- [30] Gong P. Change detection using principal component analysis and fuzzy set theory[J]. Canadian Journal of Remote Sensing, 1993, 19(1): 22-30.
- [31] Yu Z Y, Ustin S, Zhang Z C, et al. Estimation of a new canopy structure parameter for rice using smartphone photography[J]. Sensors, 2020, 20: 4011.

## Estimation of rice leaf area index combining UAV spectrum, texture features and vegetation coverage

Hang Yanhong<sup>1</sup>, Su Huan<sup>1</sup>, Yu Ziyang<sup>2</sup>, Liu Huanjun<sup>1,2\*</sup>, Guan Haixiang<sup>1</sup>, Kong Fanchang<sup>1</sup>

(1. School of Public Administration and Law, Northeast Agricultural University, Harbin 150030, China;

2. Northeast Institute of Geography and Agroecology, Chinese Academy of Sciences, Changchun 130012, China)

**Abstract:** Paddy rice as an important food crop is exactly determining the national food security in China. Leaf Area Index (LAI) is then an important indicator to evaluate crop growth and field management. Dynamic information of rice growth can be gained from the LAI with the accumulation of aboveground biomass and yield formation. The unmanned aerial vehicles (UAV)-based multispectral remote sensing technology can quickly capture the information on spatial variability of crops at the field scale, due mainly to its higher temporal and spatial resolution. The differences in rice growth can therefore be gained within the plots. As such, the vegetation indices can be used to estimate crop LAI. But there are still some saturated limitations when the LAI is large in estimating LAI. In this study, a rice LAI estimation model was constructed to investigate the ability of UAV with multiple indicators, combining spectral features, texture indices, and crop coverage. The UAV multispectral images were used to extract the spectral information, texture features, and crop coverage. A combination of different texture features, including the difference, ratio, and normalization, was calculated to obtain new texture indices, and further to improve the correlation between texture features and LAI. A one-dimensional linear model was built, where the spectral features, the texture index, and crop coverage were used as input quantities. Three types of indicators were integrated to construct a multiple stepwise regression and artificial neural network model, where the accuracy of combining multiple indicators was analyzed to estimate LAI. K-fold cross-validation was adopted to verify the present model. The results showed that there were significant correlations between six vegetation indices and rice LAI. All correlation coefficients were above 0.6 and ranked in a descending order, the Optimized Soil-Adjusted Vegetation index (OSAVI), Modified Triangular Vegetation Index 2 (MTVI2), Difference Vegetation Index (DVI), Green Normalized Difference Vegetation Index (GNDVI), Normalized Difference Vegetation Index (NDVI), and red-edge Chlorophyll Index ( $CI_{RE}$ ). The combined texture features showed that the correlation coefficient of a single texture feature with the highest correlation was 0.731 before the operation, while the texture index significantly improved the correlation between texture feature values and LAI. Specifically, the mean combination of Normalized Difference Texture Index (NDTI), Difference Texture Index (DTI), and Ratio Texture Index (RTI) presented a high correlation with LAI, where the DTI ( $mean_5$ ,  $mean_1$ ) between the near-infrared band mean and the blue band mean was the highest correlation of 0.830, 13.54% higher than that the near-infrared band mean of a single texture feature. The highest accuracy was gained in the differential texture index and crop coverage combining GNDVI, when estimating the rice LAI. The multiple stepwise regression model combining multiple indicators ( $R^2=0.866$ ,  $R^2_{adj}=0.816$ ,  $RMSE=0.308$ ) was significantly higher than that of a single vegetation index ( $R^2=0.603$ ,  $R^2_{adj}=0.563$ ,  $RMSE=0.541$ ), crop coverage ( $R^2=0.633$ ,  $R^2_{adj}=0.596$ ,  $RMSE=0.516$ ) and the LAI model constructed with a single texture index ( $R^2=0.668$ ,  $R^2_{adj}=0.635$ ,  $RMSE=0.447$ ). Better accuracy and some advantages of inversion were achieved to combine the spectral features, texture index, and crop coverage. The finding can provide a theoretical basis to estimate the structural parameters for the LAI of crops using the UAV platform in digital agriculture.

**Keywords:** UAV; leaf area index; multispectrum; coverage; texture index; rice