

基于无人机多光谱影像的柑橘冠层叶绿素含量反演

罗小波^{1,2} 谢天授^{1,2} 董圣贤³

(1. 重庆邮电大学计算机科学与技术学院, 重庆 400065;

2. 重庆邮电大学重庆市空间大数据智能技术工程研究中心, 重庆 400065;

3. 重庆新锦图信息技术有限公司, 重庆 408000)

摘要: 叶绿素是一种反映植物生长水平和健康状况的重要生理生化指标,为快速、无损地大规模获取柑橘冠层的叶绿素含量以精确指导果园管理,利用多旋翼无人机搭载多光谱传感器获取多波段反射率数据,使用多光谱阴影指数对冠层阴影和土壤背景进行剔除,计算得到植被指数与纹理特征,将地面实测的叶绿素含量作为验证,综合对比了全子集回归、偏最小二乘回归和深层神经网络的反演精度以选取最优模型。结果表明,植被指数与叶绿素含量的相关性良好;将仅使用植被指数与仅使用纹理特征的建模结果进行对比,仅使用纹理特征的模型在全子集回归和偏最小二乘回归的反演精度均有明显提升;结合植被指数与纹理特征共同建模后,全子集回归和偏最小二乘回归的反演精度相比仅使用纹理特征的模型均能获得提升;深层神经网络因其良好的非线性拟合能力,获得了最高的反演精度, R^2 、MAE、RMSE 分别为 0.665、7.69 mg/m²、9.49 mg/m²,成为本文最优模型。本研究利用无人机多光谱影像反演得到柑橘冠层叶绿素含量,为实现柑橘生长监测提供指导作用。

关键词: 柑橘; 叶绿素; 无人机; 多光谱遥感; 深层神经网络; 冠层阴影

中图分类号: S127

文献标识码: A

文章编号: 1000-1298(2023)04-0198-08

OSID:



Estimation of Citrus Canopy Chlorophyll Based on UAV Multispectral Images

LUO Xiaobo^{1,2} XIE Tianshou^{1,2} DONG Shengxian³

(1. School of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

2. Chongqing Engineering Research Center for Spatial Big Data Intelligent Technology,
Chongqing University of Posts and Telecommunications, Chongqing 400065, China

3. Chongqing Xinjintu Information Technology Co., Ltd., Chongqing 408000, China)

Abstract: Chlorophyll is an important physiological and biochemical indicator that reflects the growth level and health status of plants, how to obtain the chlorophyll content of citrus canopy quickly and non-destructively on a large scale which can accurately guide orchard management has become an urgent problem. A multi-rotor UAV DJI M600Pro with a multispectral sensor Sequoia manufactured by Parrot was used, which had four bands, including green, red, red edge and near infrared to acquire multi-band reflectance data, after removing the canopy shading and soil background by using normalized difference canopy shadow index, the vegetation index and texture characteristics were calculated. With the ground-truthed chlorophyll content values collected by handheld chlorophyll meter CCM-300 manufactured by OPTI-SCIENCES as validation, the inversion accuracy of full subset regression, partial least squares regression and deep neural network was compared to select the optimal model. The results showed that the correlation between vegetation index and chlorophyll content was high. Comparing the modeling results using only vegetation index with those using only texture features, the inversion accuracy of full subset regression and partial least squares regression of the model using only texture features was significantly improved and the inversion accuracy of full subset regression and partial least squares regression could be improved by introducing both vegetation index and texture features. The deep neural

收稿日期: 2022-06-12 修回日期: 2022-07-18

基金项目: 国家自然科学基金项目(41871226)、国家重点研发计划政府间国际科技创新合作项目(2021YFE0194700)、重庆市高新技术产业重大产业技术研发项目(D2018-82)和重庆市教委重点合作项目(HZ2021008)

作者简介: 罗小波(1975—),男,教授,博士生导师,主要从事图像处理、机器学习和无人机遥感研究,E-mail: luoxb@cqupt.edu.cn

network which had 46 input units, 4 hidden layers and 1 output unit obtained the highest inversion accuracy with R^2 , MAE, and RMSE of 0.665, 7.69 mg/m², and 9.49 mg/m², respectively, due to its good nonlinear fitting ability, it was selected as the optimal model. The research used UAV multispectral images to obtain citrus canopy chlorophyll content by inversion, which was of practical significance for monitoring citrus growth status.

Key words: citrus; chlorophyll; unmanned aerial vehicle; multispectral remote sensing; deep neural network; canopy shadow

0 引言

叶绿素含量作为反映植物生长过程中生理生化最重要的量测参数之一,不仅能够指示植物当前的营养状况和发育生长水平,也是评价植物健康的指标之一^[1]。由于作物在不同环境与生长期的叶绿素含量不同,如何及时、准确地估算作物在关键生长期的叶绿素含量成为了亟待解决的重要问题^[2]。传统的叶绿素含量测定方法包括分光光度计法、荧光光度法等,这些方法虽然更加精确,但会破坏作物,且费时费力,步骤繁琐^[3]。手持式叶绿素含量测定仪可以一定程度上解决传统方法的部分弊端,目前最为常见的测定仪是日本手持式 SPAD (Soil and plant analyzer development) 叶绿素仪,通过测量叶片对红波段和近红外波段的吸收率,计算得到叶绿素相对含量 (Relative chlorophyll content, RCC)^[4]。PINKARD 等^[5]对桉树进行了研究,结果表明通过手持式叶绿素测定仪获取到的 RCC 与传统方法测定的叶绿素含量有着明显的相关性,因此可以用 RCC 代替叶绿素含量。尽管该方法能够无损地测定作物的叶绿素含量且简化了操作步骤,但由于其以单个叶片为检测单位,难以运用在大空间尺度上^[6]。

随着遥感、计算机、通讯等技术迅速发展,无人机遥感技术平台取得了很大进展,为精准农业的进一步发展提供了技术支持^[7]。由于无人机遥感平台运行和维护成本低,操作简单,作业周期短,且空间分辨率更高,可以用来弥补现有航空、航天遥感和地面遥感系统的不足,非常适合应用于中小尺度的农田中,以获取更精确的作物生长参数^[8]。与可见光相机相比,多光谱传感器增加了红边与近红外波段,对叶片的色素和冠层结构更加敏感,与高光谱传感器相比,多光谱传感器成本低、质量小,使得载荷较小的无人机也能搭载,拓宽了不同种类无人机在农业中的应用场景^[9]。因此,利用多光谱传感器能够更加经济且有效地实现对作物种植区域边界、作物长势等大范围农情信息的快速监测。

针对农作物长势参数反演,目前研究方法主要有两种:辐射传输模型法和经验统计回归与机器学习法^[10]。其中,辐射传输模型法中最常用的是 PROSAIL 模型,该模型由 PROSPECT 和 SAIL 模型组合而成,利用 PROSPECT 模型模拟叶片在可见光到中红外的反射率和透射率及 SAIL 模型模拟冠层的辐射传输过程^[11]。通过该模型获得冠层的反射率数据并在此基础上进行各种农作物长势参数的反演,包括叶面积指数^[12]、类胡萝卜素含量^[13]、叶绿素含量等^[14]。然而,由于辐射传输模型所需的输入参数种类多且普适性差,难以进行大范围推广应用。

由于经验统计回归与机器学习法具有技术门槛较低、方法简单有效等优点,因而成为对农作物生长参数进行反演的最常用方法。基于无人机多光谱影像并计算植被指数从而构建相应的反演模型,在对多种生长参数的反演中取得了较好的精度。田军仓等^[15]基于无人机搭载的多光谱传感器获取番茄冠层上、中、下及冠层整体的图像,计算 9 种植被指数并结合偏最小二乘、支持向量机、BP 神经网络模型进行建模,结果表明冠层上部叶片构成的模型对叶绿素含量具有最好的预测精度。牛庆林等^[16]采用无人机搭载可见光和多光谱传感器同步获取冬小麦影像,并计算了多种常用可见光和多光谱植被指数,利用逐步回归和随机森林方法得到最佳叶绿素含量反演模型,结果表明结合多种植被指数可以提升反演精度和模型稳定性。刘涛等^[17]发现由不同高度无人机多光谱影像提取的多光谱植被指数与叶绿素含量和叶面积指数的相关性也不同,且通过人工神经网络进行建模可以获得最好的反演精度。

上述方法多从作物光谱信息进行考虑,而影像本身还拥有着丰富的纹理特征,引入纹理特征与光谱信息共同进行反演建模相比于仅使用光谱信息进行反演建模,精度提升明显^[18-20],而结合无人机多光谱植被指数和纹理特征进行柑橘冠层叶绿素含量估测的研究比较少。同时,由于重庆地区常年多云多雾,限制了卫星遥感技术的应用,因此本文利用无人机搭载多光谱传感器获取重庆地区地面柑橘果树影像并提取植被指数与纹理特征,结合两者并利用不同模型进行建模,选取具有最佳精度的模型估算柑橘冠层叶绿素含量,以期对柑橘果园管理提供指导。

1 材料与方法

1.1 研究区概况

研究区位于重庆市九龙坡区西彭镇真武宫村橙子城外生态农业基地(29°20′32″N, 106°19′30″E, 图1),属于亚热带季风性湿润气候,年平均最低气温17℃,年平均最高气温23℃,年平均降雨量大于1 000 mm,满足柑橘生长需求。该基地主要种植各类优质柑橘品种,包括爱媛38号、卡拉脐橙、大雅柑、春见等,根据种植行距、株距和冠幅,选择冠层间距较大的大雅柑种植区作为研究区,研究区内施肥情况、灌溉水平以及种植密度等田间管理方式均无明显差异。




图1 研究区概况及地面控制点

Fig. 1 Overview of study area and ground control points

1.2 无人机影像获取与预处理

为保证无人机获取的影像质量,结合重庆市天气情况,选取晴朗少云、太阳辐射强度稳定的2022年5月31日(夏梢期)12:00—15:00,采用大疆经纬M600Pro型六旋翼无人机,搭载Parrot公司制造的Sequoia型五通道多光谱传感器进行采集,传感器参数如表1所示。飞行前获取辐射定标灰板的图像,用于对多光谱影像进行辐射定标。飞行计划设置为飞行高度120 m,航向重叠度80%,旁向重叠度75%。为提升后期拼接影像精度,在研究区布设5个地面控制点,并使用GPS-RTK测量仪测量各控制点坐标。

表1 Sequoia型多光谱传感器参数

Tab. 1 Parameters of Sequoia multispectral sensor

波段	中心波长/nm	波宽/nm	参数	数值
绿光	550	40	光谱分辨率/bit	10
红光	660	40	水平视角/(°)	70.6
红边	735	10	垂直视角/(°)	52.6
近红外	790	40	显示视野/(°)	89.6
			空间分辨率/cm	13.58

图像采集完成后,利用Pix4DMapper软件进行

处理,将4个波段包含POS信息的共1 328幅图像导入软件中后,检查地理坐标系是否正确,之后在多幅图像中刺出地面控制点位置,使软件能够精确地匹配不同图像中的同名像元,完成稀疏点云的建立;然后基于关键匹配特征点进行点云加密,生成稠密点云、正射拼接影像、数字表面模型和包含各个波段反射率的反射图,最后得到的空间分辨率为13.58 cm。

1.3 柑橘叶绿素含量测定

由于叶片叶绿素含量具有时效性,因此采用美国OPTI-SCIENCES公司的CCM-300型手持式叶绿素测定仪与无人机采集图像同步进行柑橘叶绿素含量的测定。根据柑橘果树的特性及新老叶片的分布情况,于冠层顶部按比例选取5片新老程度存在差异且不存在明显虫害的叶片,避开叶脉进行测定,取平均值作为该果树的冠层叶绿素含量。共通过测定得到96个柑橘冠层叶绿素含量数据。

1.4 多光谱辐射定标

由于Sequoia型多光谱传感器自带的太阳光传感器可以在拍摄同时获取对应的太阳光数据,可配合Pix4DMapper软件完成辐射粗校正,但是精度不高,仍然需要配合辐射定标灰板完成室外辐射定标。辐射定标时,首先水平放置辐射定标灰板,将Sequoia型多光谱传感器远离定标灰板1.5 m左右,确保灰板中央不被阴影所阻挡后,拍摄各个波段的反射率图像,利用DN值转换为反射率公式完成定标

$$R_1 = \frac{D_{N1}}{D_{N2}} R_2$$

(1)

式中 R_1 ——目标地物单波段反射率
 D_{N1} ——目标地物单波段数字量化值
 R_2 ——辐射定标灰板单波段反射率,其中绿波段为0.174,红波段为0.218,红边波段为0.269,近红外波段为0.373
 D_{N2} ——辐射定标灰板单波段数字量化值

1.5 基于多光谱阴影指数的冠层阴影去除

土壤与果树冠层的反射率存在明显差异,同时,由于果树的冠层结构复杂且呈现三维结构,因此所获取的影像中通常包含土壤背景^[21]和冠层阴影^[22],从而对所提取到的反射率产生负面影响,降低建模反演精度。由于通过计算多光谱阴影指数得到的灰度从大到小顺序为:果树冠层、冠层阴影、土壤背景^[23],因此利用多光谱阴影指数可以很好地去除此2种干扰。目前常用的多光谱阴影指数有归一化阴影植被指数^[24](Normalized shaded vegetation index, NSVI)和归一化冠层阴影指数^[25](Normalized difference canopy shadow index, NDCSI),根据实验

结果,选取 NDCSI 作为本研究用于剔除土壤背景与冠层阴影的多光谱阴影指数,阈值设定为 0.3, NDCSI 计算公式为

$$NDCSI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} \frac{R_{RE} - R_{REMIN}}{R_{REMAX} - R_{REMIN}} \quad (2)$$

式中 R_{NIR} ——近红外波段反射率
 R_{RED} ——红波段反射率
 R_{RE} ——红边波段反射率
 R_{REMIN} ——影像红边最小值
 R_{REMAX} ——影像红边最大值

1.6 多光谱植被指数选取

植被指数通过对不同波段反射率进行运算,相比于原始波段反射率更能反映植被的健康状态,是一种简单有效的度量手段^[26]。本文选取归一化差值植被指数 (NDVI)^[27]、绿度归一化植被指数 (GNDVI)^[28]、红边归一化植被指数 (RENDVI)^[29]、比值植被指数 (RVI)^[30]、修正简单比 (MSR)^[31]、三角植被指数 (TVI)^[31]、修正叶绿素吸收反射率植被指数 (MCARI)^[32]、修正三角植被指数 (MTVI₂)^[31]、优化土壤调节植被指数 (OSAVI)^[33] 和红边叶绿素指数 (CIRE)^[34] 10 种多光谱植被指数及绿光波段 (G)、红光波段 (R)、红边波段 (RE)、近红外波段 (NIR)4 个原始波段反射率。

1.7 多光谱纹理特征提取

在频谱分析、结构化纹理分析及统计方法中,选择最为常用的灰度共生矩阵 (Gray - level co-occurrence matrix, GLCM) 对纹理进行提取分析。本文计算每个波段的 8 个基于 GLCM 的纹理特征值,包括均值 (mean)、方差 (var)、协同性 (hom)、对比度 (contrast)、相异性 (dis)、信息熵 (entropy)、二阶矩 (sec) 和相关性 (corr),根据影像空间分辨率与果树排布规律,使用 3 × 3 窗口和 45° 方向进行提取,共得到 32 个纹理特征信息。

1.8 模型构建

首先利用全子集回归分析,对所有特征变量的组合进行逐个建模,最后筛选出具有最高反演精度的变量。

然后将筛选出的变量利用偏最小二乘回归法 (Partial least squares regression, PLSR) 进行建模,相比于多元线性回归,偏最小二乘回归可以在自变量存在严重多重相关性的条件下进行建模,并能得到更好的反演精度。

随着特征变量的增多,各个特征变量之间的关系很难再用简单的线性关系进行描述,要求建模模型具有更高的非线性拟合能力。深度神经网络 (Deep neural network, DNN) 因其良好的非线性拟

合能力而在 PM_{2.5} 建模反演中得到应用,且能够取得较好精度^[35],用于 DNN 模型训练的计算机参数为: Intel® Core™ i7 - 10750H CPU @ 2.60 GHz, 16 GB 内存,1 TB 硬盘,NVIDIA GeForce RTX2070S 显卡,8 GB 显存。DNN 模型训练使用 Pytorch 1.8.1,包含由标准化后的 14 个多光谱植被指数与 32 个纹理特征构成的 46 个输入单元、4 个隐藏层和 1 个输出单元,激活函数使用线性整流函数 (ReLU),优化器使用适应性矩估计 (Adam) 优化器,批处理量为 2,学习速度 0.001,迭代次数 1 000 次。为尽可能降低过拟合现象,加入随机失活函数层^[36] (dropout),该函数层会以概率 p 丢弃其之前神经元学习到的参数,实际上可以使整个网络不对特定神经元的权重过于敏感,提升了模型泛化性,本文中, $p = 0.3$,网络结构图如图 2 所示。考虑到建模目标是对叶绿素含量进行反演,因此选用均方误差 (Mean square error, MSE) 作为模型的损失函数。




图 2 深层神经网络结构图

Fig.2 Structural of deep neural network

建模过程中,将 96 个叶绿素含量样本乱序按照比例 7:3 划分为训练集与验证集,最终获得 67 个训练样本与 29 个验证样本。采用决定系数 (Coefficient of determination, R^2)、平均绝对误差 (Mean absolute error, MAE) 和均方根误差 (Root mean square error, RMSE) 作为反演精度的评价指标。

基于无人机搭载 Sequoia 型多光谱传感器所获柑橘果树影像,结合地面所测叶绿素含量真值,在夏梢期对柑橘冠层叶绿素含量进行定量反演技术流程如图 3 所示。

2 结果与分析

2.1 叶绿素含量与多光谱植被指数相关性分析

对所有选取的多光谱植被指数与所获取的柑橘冠层叶绿素含量进行 Pearson 相关性分析,结果显示,除 RE 外,其他所有植被指数均与叶绿素含量呈显著性相关 ($P < 0.01$)。其中,4 个原始波段 G、R、




图3 柑橘冠层叶绿素含量反演流程图
Fig.3 Flow chart of citrus canopy chlorophyll content inversion

RE、NIR 与叶绿素含量的相关系数在 0.137 ~ 0.541 之间,分别为 0.541、0.537、0.137、0.382;10 个经过计算得到的植被指数 NDVI、GNDVI、RENDVI、RVI、MSR、TVI、MCARI、MTVI₂、OSAVI、CIRE 与叶绿素含量的相关系数在 0.400 ~ 0.585 之间,综合利用了各个波段之间的相关性,相比于原始波段有较明显提升,且方差较小,分别为 0.559、0.585、0.508、0.557、0.559、0.400、0.533、0.543、0.557、0.503。

2.2 叶绿素含量与多光谱纹理特征相关性分析

根据 1.7 节,对所有提取得到的多光谱纹理特征与所获取的柑橘冠层叶绿素含量进行 Pearson 相关性分析,结果如表 2 所示,其中行(X)列(Y)组合表示在 Y 波段的 X 纹理特征值,如 meanG 表示在绿波段的均值。由表 2 可知,meanG、entropyG、secG、meanR、homR、disR、entropyR、secR、meanNIR 与叶绿素含量相关性较好,在 $P < 0.01$ 的水平下呈显著相

表 2 纹理特征和叶绿素含量相关系数
Tab.2 Correlation coefficient between textural characteristics and chlorophyll content

纹理特征	波段			
	G	R	RE	NIR
mean	0.474 **	0.533 **	0.205	0.495 **
var	0.252 *	0.312 *	0.179	0.056
hom	0.268 *	0.353 **	0.016	0.015
contrast	0.178	0.249 *	0.108	0.029
dis	0.228	0.327 **	0.069	0.026
entropy	0.349 **	0.406 **	0.002	0.112
sec	0.378 **	0.407 **	0.032	0.141
corr	0.213	0.123	0.001	0.231

注: * 和 ** 分别表示 $P < 0.05$ 和 $P < 0.01$ 下相关性显著。

关,其相关系数在 0.327 ~ 0.533 之间;varG、homG、varR、contrastR 与叶绿素含量相关性一般,在 $P < 0.05$ 的水平下呈显著相关,其相关系数在 0.252 ~ 0.312 之间;其余纹理特征与叶绿素含量的相关性不明显。

2.3 柑橘冠层叶绿素含量反演建模

2.3.1 全子集回归反演建模

基于植被指数、纹理特征和结合植被指数与纹理特征进行全子集回归反演建模,其结果如表 3 所示。由表 3 可知,结合植被指数与纹理特征作为输入的全子集回归模型精度最高, R^2 、MAE、RMSE 分别为 0.459、12.22 mg/m²、14.89 mg/m²,相比于仅使用植被指数作为输入的模型,精度提升明显, R^2 提升 0.127、MAE 降低 1.14 mg/m²、RMSE 降低 1.75 mg/m²;相比于仅使用纹理特征作为输入的模型,精度提升较小, R^2 提升 0.007、MAE 降低 0.15 mg/m²、RMSE 上升 0.07 mg/m²。通过全子集回归建模结果,确定了输入 PLSR 的建模变量,分别为使用植被指数输入:R、GNDVI、NDVI、OSAVI、CIRE、RENDVI;使用纹理特征输入:meanNIR、meanG、entropyRE、disR、

表 3 全子集回归反演建模结果
Tab.3 Results of full subset regression inversion

模型	建模变量	R^2	MAE/(mg·m ⁻²)	RMSE/(mg·m ⁻²)
植被指数	R、GNDVI、NDVI、OSAVI、CIRE、RENDVI	0.332	13.36	16.64
纹理特征	meanNIR、meanG、entropyRE、disR、homR、varRE、corrR、varR、homRE	0.452	12.37	14.82
植被指数 + 纹理特征	GNDVI、contrastNIR、meanRE、entropyRE、contrastG、corrR、varRE	0.459	12.22	14.89

homR、varRE、corrR、varR、homRE;结合植被指数和纹理特征共同输入:GNDVI、contrastNIR、meanRE、entropyRE、contrastG、corrR、varRE。

2.3.2 偏最小二乘回归(PLSR)反演建模

基于全子集回归筛选出的变量进行 PLSR 反演建模,其结果如表 4 所示。由表 4 可知,结合植被指数与纹理特征作为输入和仅使用纹理特征作为输入

的 PLSR 模型精度相似,相比于仅使用植被指数作为输入的模型,精度提升明显。其中,仅使用纹理特征作为输入的 PLSR 模型精度为: R^2 为 0.495、MAE 为 12.41 mg/m²、RMSE 为 14.86 mg/m²;结合植被指数与纹理特征作为输入的 PLSR 模型精度为: R^2 为 0.495、MAE 为 12.57 mg/m²、RMSE 为 14.94 mg/m²。结合表 3、4 可知,PLSR 模型 R^2 有一定提升,但是

表 4 最小二乘回归反演建模结果
Tab.4 Results of PLSR inversion

模型	建模变量	R^2	MAE/($\text{mg}\cdot\text{m}^{-2}$)	RMSE/($\text{mg}\cdot\text{m}^{-2}$)
植被指数	R、GNDVI、NDVI、OSAVI、CIRE、RENDVI	0.352	13.64	16.93
纹理特征	meanNIR、meanG、entropyRE、disR、homR、varRE、corrR、varR、homRE	0.495	12.41	14.86
植被指数 + 纹理特征	GNDVI、contrastNIR、meanRE、entropyRE、contrastG、corrR、varRE	0.495	12.57	14.94

MAE 和 RMSE 反而有所降低。在仅使用植被指数作为输入时, R^2 提升 0.020、MAE 上升 0.28 mg/m^2 、RMSE 上升 0.29 mg/m^2 ; 在仅使用纹理特征作为输入时, R^2 提升 0.043、MAE 上升 0.04 mg/m^2 、RMSE 上升 0.04 mg/m^2 ; 在结合植被指数与纹理特征作为输入时, R^2 提升 0.036、MAE 上升 0.35 mg/m^2 、RMSE 上升 0.05 mg/m^2 。

2.3.3 深层神经网络 (DNN) 反演建模

由于多光谱植被指数与纹理特征之间数量级差异较大, 因此在进行 DNN 反演建模前, 需要先对所有特征进行标准化, 本文采用 z-score 标准化方法。区别于全子集回归与 PLSR 反演建模方法, 由于输入特征量的不同会导致网络结构的不同, 难以控制变量进行对比, 因此 DNN 反演建模直接结合植被指数与纹理特征作为输入。结合表 3、4 可知, DNN 模型在每个评价指标上相较于全子集回归和 PLSR 模型都有明显提升, R^2 、MAE、RMSE 分别为 0.665、7.69 mg/m^2 、9.49 mg/m^2 , 对比前 2 种方法中精度最高的建模结果, R^2 提升 0.17、MAE 降低 4.53 mg/m^2 、RMSE 降低 5.33 mg/m^2 。

2.4 最优模型选取

根据 R^2 、MAE、RMSE 3 种评价指标, 选取反演精度最高且数据离散性较小的 DNN 模型作为本文实验中的最优模型, 反演结果如图 4 所示。由图 4 可知, 该模型拟合线斜率非常接近 1, 表明该模型反演能力比较稳定, 是一种比较有效的提高叶绿素含量反演精度的方法。




图 4 最佳反演模型结果

Fig.4 Best inversion model results

3 讨论

在前人对植株生理生化指标的研究中, 大部分

研究者都忽视了冠层阴影及土壤背景对所提取的目标地物反射率的影响, 因此, 本文利用多光谱阴影指数结合阈值法对冠层阴影及土壤背景进行去除, 经实验, 相比于未经去除的原始数据, 绿光波段提升比较明显, 相关系数提升 0.068。

灰度共生矩阵通过统计图像空间中相隔一定距离的两像素之间的灰度关系来描述纹理, 是一种常见的提取纹理特征的手段。将多光谱纹理特征与多光谱植被指数结合进行反演建模, 可以显著提升模型的反演精度。然而, 一方面, 由于提取到的纹理特征数量众多, 对模型的拟合能力提出更高要求, 使得寻找一个效果更好的模型变得困难; 另一方面, 大部分单纹理特征与叶绿素含量的相关性都不明显, 后续可以尝试模仿植被指数的构建方式, 对纹理特征也进行归一化, 研究其相关性是否有明显提升。

深度神经网络相比于线性回归或是传统的机器学习算法, 其非线性拟合能力有明显提升, 且由于其网络结构灵活可调, 能够在包括分类、分割、反演等多个任务中取得比较好的精度。本文使用深度神经网络对柑橘冠层叶绿素含量进行反演, 并取得较高精度, 但仍有不足, 最主要的不足之处在于样本数量较少, 经过分割之后, 非常容易产生过拟合现象, 即使在网络结构中已经引入了 dropout 层, 但只是减弱了过拟合带来的负面影响, 而不能完全消除, 后续实验应当再增多样本点, 以期获取更好的反演精度。

由于无人机多光谱影像的获取时间在柑橘物候的夏梢期, 此时夏梢萌发, 不同枝桠所生长叶片的叶绿素含量有明显不同。在采集柑橘叶片叶绿素含量时, 本文采用了选取新老程度不同的叶片进行测量并求得其平均值的做法来提高其与影像中平均反射率的相关性。后续研究中, 可以尝试降低无人机飞行高度, 将所获影像从冠层尺度降低为叶片尺度, 进一步提升对柑橘果树的健康管理水平。

4 结论

(1) 通过阈值法利用多光谱阴影指数对冠层阴影和土壤背景进行剔除后, 对原始波段、多光谱植被指数、多光谱纹理特征进行 Pearson 相关性分析, 结果显示原始波段中, 绿波段和红波段与柑橘冠层叶绿素含量相关性最高, 多光谱植被指数中

除 TVI 以外,其余植被指数与柑橘冠层叶绿素含量相关系数均大于 0.5,多光谱纹理特征中,红波段均值与近红外波段均值与柑橘冠层叶绿素含量有最高相关性。

(2) 基于全子集回归的建模精度为偏最小二乘回归选择最佳输入变量,其中结合植被指数和纹理特征作为输入的模型和仅将纹理特征作为输入的模型反演精度相似,2 个模型的 R^2 、MAE、RMSE 分别为 0.495、12.57 mg/m²、14.94 mg/m² 和 0.495、12.41 mg/m²、14.86 mg/m²。仅将植被指数作为输

入不能得到很好的反演精度,验证了引入纹理特征进行柑橘冠层叶绿素含量反演的合理性。

(3) 深层神经网络可以提供强大的非线性拟合能力,将所有特征全部输入进包含 46 个输入单元、4 个隐藏层和 1 个输出单元的深层神经网络后,所获得的模型精度较好,为最佳模型,模型的 R^2 、MAE、RMSE 分别为 0.665、7.69 mg/m²、9.49 mg/m²。表明利用深层神经网络结合多光谱植被指数与纹理特征能够比较有效地对柑橘冠层叶绿素含量进行反演,对柑橘果园的管理具有一定指导作用。

参 考 文 献

- [1] 孙刚,黄文江,陈鹏飞,等. 轻小型无人机多光谱遥感技术应用进展[J]. 农业机械学报,2018,49(3):1-17.
SUN Gang, HUANG Wenjiang, CHEN Pengfei, et al. Advances in UAV-based multispectral remote sensing applications[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018,49(3):1-17. (in Chinese)
- [2] GITELSON A A, MERZLYAK M N. Remote estimation of chlorophyll content in higher plant leaves[J]. International Journal of Remote Sensing, 1997, 18(12):2691-2697.
- [3] AMIRRUDDIN A D, MUHAMMAD F M, ISMAIL M H, et al. Hyperspectral remote sensing for assessment of chlorophyll sufficiency levels in mature oil palm (*Elaeis guineensis*) based on frond numbers: analysis of decision tree and random forest[J]. Computers and Electronics in Agriculture, 2020, 169: 105221.
- [4] STEELE M R, GITELSON A A, RUNDQUIST D C. A comparison of two techniques for nondestructive measurement of chlorophyll content in grapevine leaves[J]. Agronomy Journal, 2008, 100(3):779-782.
- [5] PINKARD E A, PATEL V, MOHAMMED C. Chlorophyll and nitrogen determination for plantation-grown *Eucalyptus nitens* and *E. globulus* using a non-destructive meter[J]. Forest Ecology and Management, 2006, 223(1-3):211-217.
- [6] PAGOLA M, ORTIZ R, IRIGOYEN I, et al. New method to assess barley nitrogen nutrition status based on image colour analysis comparison with SPAD-502[J]. Computers and Electronics in Agriculture, 2009, 65(2):213-218.
- [7] 白由路,金继运,杨俐苹,等. 低空遥感技术及其在精准农业中的应用[J]. 土壤肥料,2004(1):3-6.
BAI Youlu, JIN Jiyun, YANG Liping, et al. Technology of low altitude remote sensing and its applications in precision agriculture[J]. Soil and Fertilizer Sciences in China, 2004(1):3-6. (in Chinese)
- [8] 汪沛,罗锡文,周志艳,等. 基于微小型无人机的遥感信息获取关键技术综述[J]. 农业工程学报,2014,30(18):1-12.
WANG Pei, LUO Xiwen, ZHOU Zhiyan, et al. Key technology for remote sensing information acquisition based on micro UAV[J]. Transactions of the CSAE,2014,30(18):1-12. (in Chinese)
- [9] JIN X, ZARCO-TEJADA P, SCHMIDHALTER U, et al. High-throughput estimation of crop traits: a review of ground and aerial phenotyping platforms[J]. IEEE Geoscience and Remote Sensing Magazine, 2020, 9(1):200-231.
- [10] 刘忠,万炜,黄晋宇,等. 基于无人机遥感的农作物长势关键参数反演研究进展[J]. 农业工程学报,2018,34(24):60-71.
LIU Zhong, WAN Wei, HUANG Jinyu, et al. Progress on key parameters inversion of crop growth based on unmanned aerial vehicle remote sensing[J]. Transactions of the CSAE, 2018, 34(24):60-71. (in Chinese)
- [11] 梁顺林. 定量遥感[M]. 北京:科学出版社,2009.
- [12] 褚洪亮,肖青,柏军华,等. 基于无人机遥感的叶面积指数反演[J]. 遥感技术与应用,2017,32(1):140-148.
CHU Hongliang, XIAO Qing, BAI Junhua, et al. The retrieval of leaf area index based on remote sensing by unmanned aerial vehicle[J]. Remote Sensing Technology and Application, 2017,32(1):140-148. (in Chinese)
- [13] ZARCO-TEJADA P J, GUILLÉN-CLIMENT M L, HERNÁNDEZ-CLEMENTE R, et al. Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV)[J]. Agricultural and Forest Meteorology, 2013, 171:281-294.
- [14] YU F, XU T, DU W, et al. Radiative transfer models (RTMs) for field phenotyping inversion of rice based on UAV hyperspectral remote sensing[J]. International Journal of Agricultural and Biological Engineering, 2017, 10(4):150-157.
- [15] 田军仓,杨振峰,冯克鹏,等. 基于无人机多光谱影像的番茄冠层 SPAD 预测研究[J]. 农业机械学报,2020,51(8):178-188.
TIAN Juncang, YANG Zhenfeng, FENG Kepeng, et al. Prediction of tomato canopy SPAD based on UAV multispectral image[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(8):178-188. (in Chinese)
- [16] 牛庆林,冯海宽,周新国,等. 冬小麦 SPAD 值无人机可见光和多光谱植被指数结合估算[J]. 农业机械学报,2021,52(8):183-194.
NIU Qinglin, FENG Haikuan, ZHOU Xinguo, et al. Combining UAV visible light and multispectral vegetation indices for estimating SPAD value of winter wheat[J]. Transactions of the Chinese Society for Agricultural Machinery,2021,52(8):183-194. (in Chinese)
- [17] 刘涛,张寰,王志业,等. 利用无人机多光谱估算小麦叶面积指数和叶绿素含量[J]. 农业工程学报,2021,37(19):65-72.
LIU Tao, ZHANG Huan, WANG Zhiye, et al. Estimation of the leaf area index and chlorophyll content of wheat using UAV multi-spectrum images[J]. Transactions of the CSAE, 2021, 37(19):65-72. (in Chinese)

[18] 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,2019, 35(11):63–74.
CHEN Peng, FENG Haikuan, LI Changchun, et al. Estimation of chlorophyll content in potato using fusion of texture and spectral features derived from UAV multispectral image[J]. Transactions of the CSAE, 2019, 35(11): 63–74. (in Chinese)

[19] YANG K, GONG Y, FANG S, et al. Combining spectral and texture features of UAV images for the remote estimation of rice LAI throughout the entire growing season[J]. Remote Sensing, 2021, 13(15): 3001.

[20] 杭艳红,苏欢,于滋洋,等. 结合无人机光谱、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.
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 CSAE, 2021, 37(9): 64–71. (in Chinese)

[21] 孟沌超,赵静,兰玉彬,等. 基于无人机可见光影像的玉米冠层 SPAD 反演模型研究[J]. 农业机械学报,2020,51(增刊 2):366–374.
MENG Dunchao,ZHAO Jing,LAN Yubin,et al. SPAD inversion model of corn canopy based on UAV visible light image[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(Supp. 2):366–374. (in Chinese)

[22] 师翊,耿楠,胡少军,等. 基于随机森林回归算法的苹果树冠层光照分布模型[J]. 农业机械学报,2019,50(5):214–222.
SHI Yi,GENG Nan,HU Shaojun,et al. Illumination distribution model of apple tree canopy based on random forest regression algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(5):214–222. (in Chinese)

[23] 李美炫,朱西存,白雪源,等. 基于无人机影像阴影去除的苹果树冠层氮素含量遥感反演[J]. 中国农业科学,2021, 54(10):2084–2094.
LI Meixuan, ZHU Xicun, BAI Xueyuan, et al. Remote sensing inversion of nitrogen content in apple canopy based on shadow removal in UAV multi-spectral remote sensing images[J]. Scientia Agricultura Sinica, 2021, 54(10): 2084–2094. (in Chinese)

[24] XU Z H, LIN L, WANG Q F, et al. Construction and application effects of normalized shaded vegetation index (NSVI)[J]. Journal of Infrared and Millimeter Waves, 2018, 37(2):155–162.

[25] TANG S. Analysis of vegetation red edge with different illuminated/shaded canopy proportions and to construct normalized difference canopy shadow index[J]. Remote Sensing, 2019, 11(10): 1192.

[26] 汪小钦,王苗苗,王绍强,等. 基于可见光波段无人机遥感的植被信息提取[J]. 农业工程学报,2015,31(5):152–159.
WANG Xiaoqin, WANG Miaomiao, WANG Shaoqiang, et al. Extraction of vegetation information from visible unmanned aerial vehicle images[J]. Transactions of the CSAE, 2015, 31(5): 152–159. (in Chinese)

[27] SCHNELL J A. Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation[R]. NASA/GSFCT Type Final Report, 1974.

[28] 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 Sensing of Environment, 1996, 58(3):289–298.

[29] CAO Q, MIAO Y, SHEN J, et al. Improving in-season estimation of rice yield potential and responsiveness to topdressing nitrogen application with crop circle active crop canopy sensor[J]. Precision Agriculture, 2015, 17(2):136–154.

[30] 于丰华,许童羽,郭忠辉,等. 基于红边优化植被指数的寒地水稻叶片叶绿素含量遥感反演研究[J]. 智慧农业(中英文), 2020, 2(1): 77–86.
YU Fenghua, XU Tongyu, GUO Zhonghui, et al. Remote sensing inversion of chlorophyll content in rice leaves in cold region based on optimizing red-edge vegetation index (ORVI)[J]. Smart Agriculture, 2020, 2(1): 77–86. (in Chinese)

[31] 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.

[32] DAUGHTRY C, WALTHALL C L, KIM M S, et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance[J]. Remote Sensing of Environment, 2000, 74(2):229–239.

[33] BARET S F. Optimization of soil-adjusted vegetation indices[J]. Remote Sensing of Environment, 1996, 55(2): 95–107.

[34] GITELSON A A, VINA A, CIGANDA V, et al. Remote estimation of canopy chlorophyll content in crops[J]. Geophysical Research Letters, 2005, 32(8): L08403.

[35] 刘林钰,张永军,李彦胜,等. 基于深度学习的华东地区 PM_{2.5} 浓度遥感反演[J]. 环境科学,2020,41(4):1513–1519.
LIU Linyu, ZHANG Yongjun, LI Yansheng, et al. PM_{2.5} inversion using remote sensing data in eastern China based on deep learning[J]. Environmental Science,2020,41(4):1513–1519. (in Chinese)

[36] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1):1929–1958.