

基于超分辨率重建与机器学习的油菜苗情监测方法

杨 扬¹ 刘 洋¹ 苏 宸¹ 赵 杰² 张强强³ 周广生²

(1. 华中农业大学工学院, 武汉 430070; 2. 华中农业大学植物科学技术学院, 武汉 430070;

3. 安徽农业大学农学院, 合肥 230036)

摘要: 为优化养分管理和确保植株正常生长, 以无人机遥感技术高效且非破坏采集田间作物苗情信息, 监测油菜苗期的叶面积指数(LAI)与叶绿素相对含量(SPAD)。针对无人机因飞行高度与图像分辨率相互制约, 监测效率与监测精度难以兼顾的问题, 采用超分辨率重建方法, 融合较低飞行高度拍摄高分辨率影像, 重建较高飞行高度拍摄影像, 建模完成后可通过拍摄飞行影像监测 LAI 和 SPAD。试验设置 3 个氮肥梯度、3 个播期、3 个种植密度处理, 在苗期利用无人机分别采集 20 m 及 40 m 2 个飞行高度的油菜苗影像, 采用 SRRestnet 方法, 对 40 m 影像进行超分辨率重建。基于 20 m、40 m 及 40 m 重建影像中提取的 3 种特征组合, 利用偏最小二乘回归(PLSR)、随机森林(RF)、支持向量回归(SVR)3 种机器学习方法对 LAI 和 SPAD 进行监测。结果表明, 超分辨率重建后的图像在表型苗情监测中表现出良好效果, PLSR 监测 LAI、RF 监测 SPAD 的监测精度最高, 且 40 m 重建图像的作业效率相比于 20 m 图像提高 48.6%。

关键词: 油菜; 苗情监测; 叶面积指数; 叶绿素相对含量; 超分辨率重建; 机器学习

中图分类号: S127 文献标识码: A 文章编号: 1000-1298(2024)06-0196-06

OSID:



Oilseed Rape Seedling Monitoring Method Based on Super-resolution Reconstruction and Machine Learning

YANG Yang¹ LIU Yang¹ SU Chen¹ ZHAO Jie² ZHANG Qiangqiang³ ZHOU Guangsheng²

(1. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China

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

3. College of Agriculture, Anhui Agricultural University, Hefei 230036, China)

Abstract: In order to optimize nutrient management and ensure normal plant growth, UAV remote sensing technology was used to efficiently and non-destructively collect crop seedling information in the field, and to monitor the leaf area index (LAI) and the relative chlorophyll content (SPAD) of oilseed rape during the seedling stage. It is difficult to balance the monitoring efficiency and monitoring accuracy due to the constraints of flight altitude and image resolution of UAVs. A super-resolution reconstruction method was adopted to integrate the high-resolution images taken at lower flight altitudes and reconstruct the images taken at higher flight altitudes, so that LAI and SPAD could be monitored by the flight images taken after the modeling was completed. Three nitrogen fertilizer gradients, three sowing periods, and three planting densities were set up, and the UAV was used to collect the images of oilseed rape seedlings at 20 m and 40 m flight altitudes respectively in seedling stage, and SRRestnet method was used to analyze the seedling images at 40 m and 40 m flight altitudes respectively. SRRestnet method, and super-resolution reconstruction was performed on the 40 m images. Based on the three combinations of features extracted from the 20 m, 40 m and 40 m reconstructed images, three machine learning methods, namely partial least squares regression (PLSR), random forest (RF), and support vector regression (SVR), were utilized to monitor LAI and SPAD. The results showed that the super-resolution reconstructed images performed well in phenological seedling monitoring, and PLSR monitoring of LAI and RF monitoring of SPAD had the highest monitoring accuracy, and the operational efficiency of the 40 m reconstructed images was 48.6% higher compared with that of the 20 m images.

Key words: oilseed rape; seedling monitoring; leaf area index; relative chlorophyll content; super-resolution reconstruction; machine learning

0 引言

油菜籽是世界第 2 大植物油来源^[1], 其籽粒含油量高, 可以为人体提供所需的油脂^[2]。油菜的早期生长阶段, 特别是幼苗时期, 以叶面积指数(Leaf area index, LAI)与叶绿素相对含量(Soil plant analysis development, SPAD)为代表的油菜苗情特征, 对科学施肥、病虫害防控等调控措施至关重要, 有助于优化养分管理和保障作物健康生长^[3]。

无人机遥感技术可以高效且非破坏采集田间作物苗情信息^[4-5]。植被指数已广泛用来定性和定量地监测作物苗情^[6]。ZHANG 等^[7]和 CAO 等^[8]分别以冬小麦和甜菜为研究对象, 以光谱数据为输入, 通过偏最小二乘回归(Partial least squares regression, PLSR)、支持向量机回归(Support vector machine regression, SVR)等机器学习算法建立了作物表型监测模型。为了提高作物苗情监测模型的精度, DU 等^[9]、谷晓博等^[10]和 JIANG 等^[11]以无人机获取的作物的植被指数特征和纹理特征为输入, 采用线性回归(Linear regression, LR)、反向传播神经网络(Back propagation neural network, BPNN)和随机森林(Random forest, RF)算法建立 LAI 估计模型, 结果表明增加纹理特征作为模型输入可以提高监测精度。

本文将超分辨率重建技术^[12]引入油菜苗情监测中, 对高空无人机图像进行重建, 以图像中提取的植被指数和纹理指数作为监测模型输入, 以油菜苗期 LAI 与 SPAD 为输出, 采用多种机器学习方法建立油菜苗情监测模型, 以期提供一种高精度、高效率的作物苗情监测技术。

1 材料和方法

1.1 大田试验概况

油菜苗情监测试验于 2022 年 9 月—2023 年 2 月在荆州市沙市区农业科学院试验田进行, 如图 1 所示。播种方式为人工条播, 种植品种为华油杂 50。开展 3 个氮肥梯度、3 个播期、3 个种植密度处理, 共计 226 个小区的油菜苗期监测试验。

1.2 数据采集

无人机图像于 2023 年 1 月 10—11 日和 2023 年 1 月 30—31 日, 通过大疆御 Mavic 3 型无人机进行可见光影像采集。飞行高度 h 为 20 m 和 40 m。单个试验小区在高度 20 m 和 40 m 下的分辨率分别为 1 663 像素 \times 1 881 像素和 825 像素 \times 949 像素左右。分别使用 LP-80 型冠层分析仪与 SPAD-502P

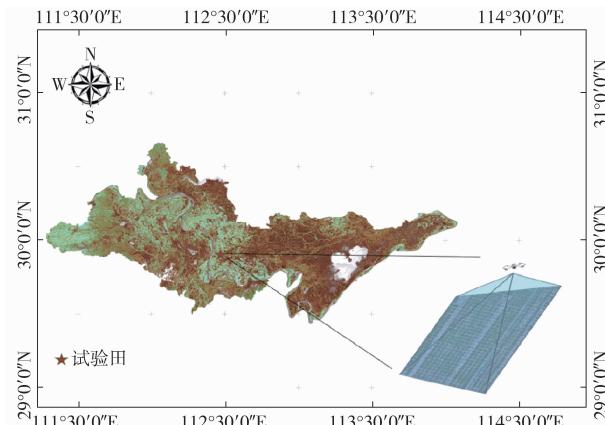


图 1 油菜苗情监测试验地

Fig. 1 Oilseed rape phenotypic monitoring trial site

型手持式叶绿素仪测量试验小区油菜的 LAI 和 SPAD。

2 基于无人机遥感图像的超分辨率重建

2.1 无人机遥感图像预处理

2.1.1 图像拼接与裁剪

使用软件 DJI Terra 对无人机图像进行拼接。基于深度学习的超分辨率重建需要成对的图像数据集^[13], 故在对图像进行超分辨率重建前, 需要进行图像匹配。为尽可能减少成对图像在图像匹配时的误差, 按经纬度对油菜高度 20 m 和 40 m 拼接图像进行裁剪。

2.1.2 图像匹配

为减小匹配误差, 使用尺度不变特征转换方法(Scale-invariant feature transform, SIFT)^[14]进行图像匹配, 使得 20 m 与 40 m 图像对齐。通过自动裁剪获取成对图像, 将匹配前 2 个高度下的图像像素差由 17 左右降至 13 左右, 进一步降低了像素点不匹配对深度学习模型训练造成的不良影响。最后, 对裁剪后的 35 对图像进一步进行有重叠裁剪, 共得到 315 对成对图像, 其中 20 m 图像的分辨率被保存为 800 像素 \times 800 像素, 40 m 图像的分辨率被保存为 400 像素 \times 400 像素。

2.2 超分辨率重建方法与评价指标

通过超分辨率重建来提升图像分辨率进而弥补飞行高度带来的信息损失。选取一种插值技术(双三次插值技术(Bicubic))和 3 种深度学习网络模型(Super-resolution convolution neural network (SRCNN)、Laplacian pyramid super-resolution network (LapSRN)、SRResnet^[15])对油菜田图像进行超分辨率重建。使用 2 个图像重建领域常用的评价指标: 峰值信噪比(Peak signal-to-noise ratio, PSNR)和结构相似性(Structural similarity, SSIM)对重建的效果进行

评价,2个指标的数值越大表明重建效果越好^[16]。

2.3 模型训练与对比

将无人机采集的315对20 m和40 m图像按照比例8:2随机划分训练集和测试集,得到训练集252对,测试集63对。训练完成后,为了比较不同

方法对40 m拍摄图像重建的效果,在测试集中选取两对图像为例,分别采用4种方法重建的图像进行对比。图2分别展示了测试集中当油菜叶片较小和较大时,对40 m重建与对应20 m图像分别采用4种方法阈值分割后的相似程度。

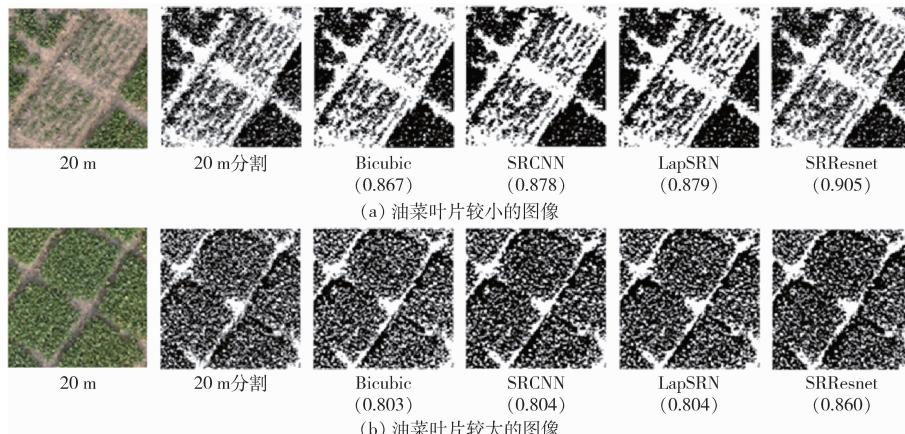


图2 4种方法对测试集中高度40 m的图像重建后与相应高度20 m图像的阈值分割对比

Fig. 2 Comparison of threshold segmentation of reconstructed 40 m image with corresponding 20 m height image by four methods

图2中的数字表示4种方法所得到图像与20 m图像阈值分割后逐个像素点的一致性。可以看出,SRResnet得到的重建图像与20 m图像最相似,且重建后得到更好的纹理细节。使用PSNR和SSIM 2个评价指标评估重建效果,结果如表1所示。基于深度学习的超分重建结果在SSIM指标上表现好于Bicubic,SRResnet的2个指标都获得了最优值,本文选用SRResnet来进行后续高度40 m小区田块图像的重建。

表1 不同重建方法的PSNR和SSIM平均值

Tab. 1 PSNR and SSIM average values for different reconstruction methods

方法	PSNR	SSIM
Bicubic	22.32	0.494
SRCNN	22.66	0.650
LapSRN	21.29	0.656
SRResnet	24.61	0.659

3 基于机器学习的油菜苗情监测

3.1 20 m、40 m与40 m重建图像的特征提取

提取裁剪后的试验小区RGB图像的可见光波段,计算了10种常见的可见光植被指数:红蓝差值指数(Red-blue difference index, RBDI)、绿红差值指数(Green-red difference index, GRDI)、绿蓝差值指数(Green-blue difference index, GBDI)、归一化蓝色指数(Normalized blue index, NBI)、归一化红绿差异指数(Normalized red-green difference index, NRGDI)^[17]、归一化绿蓝差异指数(Normalized green-blue difference index, NGBDI)、归一化绿红差异指数(Normalized green-red difference index, NGRDI)^[19]、超绿指数(Excess green index, ExG)^[20]、超红指数(Excess red index, ExR)^[21]、超绿超红差分指数(Excess green minus excess red index, ExGR)^[22]。

为了提高作物表型监测模型精度,进一步从RGB图像中提取纹理特征(Texture feature, T)来完善监测模型。本文采用灰度共生矩阵方法(Gray-level covariance matrix, GLCM)对裁剪后的图像进行纹理特征提取^[23]。选取的8种常用纹理指数分别为:同质性、对比度、熵、二阶矩、差异性、均值、方差和相关性。

3.2 相关性分析

为了确定自变量与因变量之间的线性关系,以选择最具预测性能的自变量来建立模型,在油菜苗情建模前,利用皮尔逊相关性对提取图像的特征与实测的苗情数值进行相关性分析,确定最佳监测特征。

在对特征与实测LAI和SPAD进行相关性分析之前,为了全面分析实测LAI与SPAD的范围和数据分布特征,绘制了LAI与SPAD实测数据分析图,如图3所示,实测LAI与SPAD均未出现异常值,说明在进行数据采集过程中未出现过失误差。同时中位线位置与均值位置较为接近,说明实测LAI与SPAD数据分布较为均匀,没有出现数据分布偏斜的情况。

对人工实测的LAI与SPAD和不同监测高度的

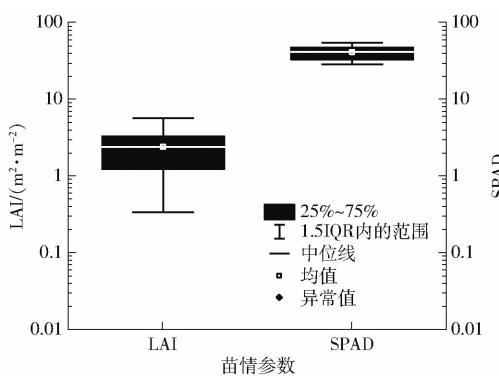


图3 LAI与SPAD实测数据分布图

Fig. 3 Distribution of LAI and SPAD measured data

图像特征进行皮尔逊相关性分析,结果如表2所示。可见光植被指数和纹理指数均与 LAI 有较强相关性;大部分可见光植被指数和纹理指数均与 SPAD 有较强相关性。本文选取特征的标准是在不同高度下相关性均显著且与 LAI 和 SPAD 的显著性方向一致。因此,选取除 NRGDI 外的其它 9 个植被指数以及纹理指数中的均值、方差作为 LAI 的建模因子;选取 RBDI、GBDI、NBI、NRGDI、二阶矩、同质性、相关性作为 SPAD 的建模因子。

3.3 油菜苗情监测模型构建方法及评价指标

以相关性分析后选取的植被指数特征与纹理特征为输入,以田间实测 LAI 与 SPAD 为输出,采用 PLSR、RF 和 SVR 建模方法构建 LAI 和 SPAD 的监测模型。使用 R^2 、平均绝对误差 (Mean absolute error, MAE)、均方根误差 (Root mean square error, RMSE) 作为监测模型的评价指标。

3.4 基于机器学习的油菜苗情监测结果

对提取的不同高度下图像特征,实测的 154 个 LAI 数据与 109 个 SPAD 数据分别按照比例 8:2

表2 不同监测高度的图像特征与 LAI 和 SPAD 相关性

Tab. 2 Correlation of characteristics of images at different monitoring heights with LAI and SPAD

特征	LAI		SPAD	
	20 m	40 m	20 m	40 m
RBDI	-0.705 **	-0.682 **	-0.272 **	-0.207 *
GRDI	0.861 **	0.863 **	-0.022	0.002
GBDI	0.536 **	0.515 **	-0.316 **	0.248 **
NBI	-0.594 **	-0.619 **	0.495 **	0.220 *
NRGDI	-0.022	0.057	-0.536 **	-0.258 **
NGBDI	0.749 **	0.763 **	-0.369 **	-0.143
NGRDI	0.871 **	0.878 **	-0.036	0.046
ExG	0.786 **	0.781 **	-0.165	-0.124
ExR	-0.865 **	-0.870 **	0.040	-0.005
ExGR	0.849 **	0.852 **	-0.107	-0.061
同质性	0.303 **	-0.353 **	-0.230 *	-0.276 **
对比度	0.013	0.241 **	0.098	0.270 **
熵	-0.193 **	0.269 **	0.212 *	0.269 **
角二阶矩	-0.387 **	0.481 **	0.255 **	0.229 *
差异性	-0.090	0.379 **	0.125	0.292 **
均值	-0.602 **	-0.689 **	0.103	-0.021
方差	-0.567 **	-0.658 **	0.087	0.001
相关性	0.381 **	-0.410 **	-0.229 *	-0.290 **

注: ** 表示 0.01 显著水平, * 表示 0.05 显著水平。

进行训练集和测试集划分。为了更准确地评估模型性能,采用 5 折交叉验证法和 3 种建模方法分别对 20 m、40 m 重建、40 m 图像所提取的特征组合进行监测。最后,使用 R^2 、MAE、RMSE 进行评估。3 种监测模型在训练集和测试集的监测效果如表 3 所示。其中 PLSR 和 RF 分别监测 LAI 和 SPAD 的效果最佳。图 4 比较了 3 种模型的监测值与实测值的拟合效果,可以发现高度 20 m 与 40 m 重建图像的监测结果与实测值所拟合线都很靠近 1:1 蓝色虚线。

表3 基于 20 m、40 m 和 40 m 重建图像的 PLSR、SVR 和 RF 苗情监测效果对比

Tab. 3 Comparison of effectiveness of PLSR, SVR and RF seedling monitoring based on 20 m, 40 m and 40 m reconstructed images

苗情 指标	建模 高度/m	PLSR			SVR			RF		
		R^2	MAE	RMSE	R^2	MAE	RMSE	R^2	MAE	RMSE
LAI	20	0.769	0.233 m ² /m ²	0.312 m ² /m ²	0.776	0.213 m ² /m ²	0.309 m ² /m ²	0.765	0.237 m ² /m ²	0.313 m ² /m ²
	40	0.756	0.247 m ² /m ²	0.319 m ² /m ²	0.753	0.238 m ² /m ²	0.317 m ² /m ²	0.735	0.256 m ² /m ²	0.325 m ² /m ²
	40(重建)	0.744	0.244 m ² /m ²	0.319 m ² /m ²	0.768	0.232 m ² /m ²	0.228 m ² /m ²	0.748	0.237 m ² /m ²	0.311 m ² /m ²
SPAD	20	0.534	1.391	1.813	0.479	2.244	0.538	0.538	1.565	1.806
	40	0.445	1.556	1.985	0.385	2.499	0.440	0.440	1.558	1.995
	40(重建)	0.524	1.298	1.839	0.426	2.487	0.501	0.501	2.09	2.709

从整体上看,PLSR 和 RF 分别在 LAI 和 SPAD 监测的所有训练集上的评价指标皆具有最优的值。表 4 记录了不同高度下无人机作业时间与 LAI 和 SPAD 监测的最佳 R^2 。从无人机作业时间以及油菜苗情监测效果的角度出发,将 40 m 图像超分辨率重

建至 20 m 图像,可以在保证监测模型精度稳定的同时作业效率提高 48.6%。

4 结论

(1) 针对农业中无人机监测任务的飞行成本与

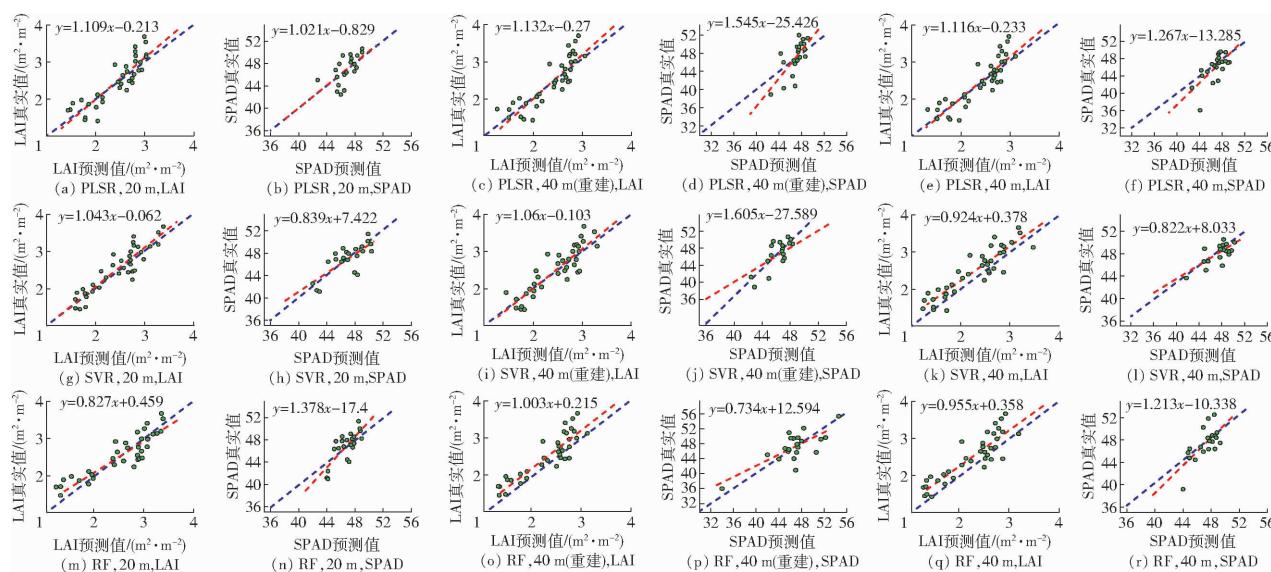


图 4 3 种机器学习方法在 20 m、40 m 和 40 m 重建图像上的苗情监测与实测值散点图

Fig. 4 Scatterplots of seedling monitoring versus measured values on 20 m, 40 m and 40 m reconstructed images by three machine learning methods

表 4 无人机不同高度作业效率与效果

Tab. 4 Operational efficiency and effectiveness of UAV at different heights

参数	建模高度/m		
	20	40	40(重建)
作业时间/min	25.7	13.2	13.2
R ² (LAI)	0.776	0.753	0.768
R ² (SPAD)	0.538	0.445	0.524

监测精度难以平衡的问题,本文将超分辨率重建技术引入油菜苗情监测问题中,对无人机图像进行图像增强,从而获得更准确、可靠的图像特征,在保证油菜苗情监测精度的同时,减少飞行时间,提升监测效率。

(2) 在荆州市沙市区农业科学院试验田开展油菜苗期监测试验,利用无人机采集 2 个飞行高度的

油菜苗影像,田间实测了 LAI 数据和 SPAD 数据。通过 SIFT 算法对 40 m 图像进行预处理,使用 4 种图像超分辨率重建方法对油菜大田影像进行重建,其中 SRResnet 达到了最佳重建质量,PSNR 为 24.61,SSIM 为 0.659。

(3) 提取原始图像及重建图像的植被指数特征与纹理特征,并将其与实测的 LAI 与 SPAD 进行相关性分析,筛选出最佳特征作为监测模型输入,使用 3 种机器学习算法建立油菜苗情监测模型。结果表明,超分辨率重建后的图像在苗情监测中表现良好,采用 PLSR 监测 LAI、RF 监测 SPAD 的监测精度最高,40 m 重建图像的 LAI 与 SPAD 最高 R² 分别为 0.768 和 0.524,接近飞行高度 20 m 的 R² (分别为 0.776 和 0.538),且作业效率提高 48.6%,大大节省了时间成本。

参 考 文 献

- [1] ORTEGA-RAMOS P A, COSTON D J, SEIMANDI-CORDA G, et al. Integrated pest management strategies for cabbage stem flea beetle (*Psylliodes chrysocephala*) in oilseed rape[J]. GCB Bioenergy, 2022, 14(3): 267–286.
- [2] ASHKIANI J A, SAYFZADEH S, SHIRANI R, et al. Effects of foliar zinc application on yield and oil quality of rapeseed genotypes under drought stress[J]. Journal of Plant Nutrition, 2020, 43(11): 1594–1603.
- [3] KIRKEGAARD A J, LILLEY M J, BRILL D R, et al. The critical period for yield and quality determination in canola[J]. Field Crops Research, 2018, 222: 180–188.
- [4] VROCHIDOU E, BAZINAS C, MANIOS M, et al. Machine vision for ripeness estimation in viticulture automation[J]. Horticulturae, 2021, 7(9): 282.
- [5] WILLKOMM M, BOLTEN A, BARETH G. Non-destructive monitoring of rice by hyperspectral in-field spectrometry and UAV-based remote sensing: case study of field-grown rice in North Rhine-Westphalia, Germany[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, XLI – B1: 1071–1077.
- [6] LUKAS V, IGOR H, ANTONÍN K, et al. Using UAV to identify the optimal vegetation index for yield prediction of oil seed rape (*Brassica napus* L.) at the flowering stage[J]. Remote Sensing, 2022, 14: 19.
- [7] ZHANG J, CHENG T, GUO W, et al. Leaf area index estimation model for UAV image hyperspectral data based on wavelength variable selection and machine learning methods[J]. Plant Methods, 2021, 17(1): 49.

- [8] CAO Y, LI G L, LUO Y, et al. Monitoring of sugar beet growth indicators using wide-dynamic-range vegetation index (WDRVI) derived from UAV multispectral images[J]. Computers and Electronics in Agriculture, 2020, 171: 105331.
- [9] DU L, YANG H, SONG X, et al. Estimating leaf area index of maize using UAV-based digital imagery and machine learning methods[J]. Scientific Reports, 2022, 12(1): 15937.
- [10] 谷晓博,程智楷,周智辉,等. 基于特征降维和机器学习的覆膜冬小麦 LAI 遥感反演[J]. 农业机械学报, 2023, 54(6): 148–157, 167.
GU Xiaobo, CHENG Zhikai, ZHOU Zhihui, et al. Remote sensing inversion of LAI for mulched winter wheat based on feature downscaling and machine learning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54 (6): 148 – 157, 167. (in Chinese)
- [11] JIANG J, JOHANSEN K, STANSCHEWSKI C S, et al. Phenotyping a diversity panel of quinoa using UAV-retrieved leaf area index, SPAD-based chlorophyll and a random forest approach[J]. Precision Agriculture, 2022, 23(3): 961–983.
- [12] HUANG Y, MIYAZAKI T, LIU X, et al. Infrared image super-resolution: systematic review and future trends[J]. arXiv Preprint, arXiv: 2212.12322, 2022.
- [13] CHEN H G, HE X H, QING L, et al. Real-world single image super-resolution: a brief review[J]. Information Fusion, 2022, 79: 124–145.
- [14] NG P C, HENIKOFF S. SIFT: predicting amino acid changes that affect protein function[J]. Nucleic Acids Research, 2003, 31(13): 3812–3814.
- [15] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks[C]// Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, 2016.
- [16] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4681–4690.
- [17] KAWASHIMA S, NAKATANI M. An algorithm for estimating chlorophyll content in leaves using a video camera[J]. Annals of Botany, 1998, 81(1): 49–54.
- [18] WOEBBECKE D M, MEYER G E, BARGEN K, et al. Plant species identification, size, and enumeration using machine vision techniques on near-binary images[J]. Optics in Agriculture and Forestry, 1993, 1836: 208–219.
- [19] HUNT E R, CAVIGELLI M, DAUGHTRY C S, et al. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status[J]. Precision Agriculture, 2005, 6: 359–378.
- [20] WOEBBECKE D M, MEYER G E, BARGEN K, et al. Color indices for weed identification under various soil, residue, and lighting conditions[J]. Transactions of the ASAE, 1995, 38(1): 259–269.
- [21] MEYER G E, HINDMAN T W, LAKSMI K. Machine vision detection parameters for plant species identification[J]. Precision Agriculture and Biological Quality, 1999, 3543: 327–335.
- [22] MEYER G E, NETO J C. Verification of color vegetation indices for automated crop imaging applications[J]. Computers and Electronics in Agriculture, 2008, 63(2): 282–293.
- [23] 宋荣杰,宁纪锋,刘秀英,等. 基于纹理特征和 SVM 的 QuickBird 影像苹果园提取[J]. 农业机械学报, 2017, 48(3): 188–197.
SONG Rongjie, NING Jifeng, LIU Xiuying, et al. QuickBird image apple orchard extraction based on texture features and SVM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(3): 188 – 197. (in Chinese)

(上接第 185 页)

- [26] 赵文举,李聪聪,马宏,等. 基于 Sentinel - 2 超分辨率影像的干旱区水体提取方法[J]. 农业机械学报, 2023, 54(10): 316–328.
ZHAO Wenju, LI Congcong, MA Hong, et al. Water body extraction method in arid area based on Sentinel - 2 super-resolution images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 316 – 328. (in Chinese)
- [27] 周婷,汪炎,邹俊,等. 基于 PCA 和 SVM 的遥感影像水体提取方法及验证[J]. 水资源保护, 2023, 39(2): 180–189.
ZHOU Ting, WANG Yan, ZOU Jun, et al. Method and validation of water body extraction from remote sensing images based on PCA and SVM[J]. Water Resources Conservation, 2023, 39(2): 180 – 189. (in Chinese)
- [28] 蔡丹丰,胡求光,魏昕伊. 基于 Sentinel - 1 影像的浙江省沿海养殖池塘提取与管理[J]. 农业机械学报, 2023, 54(2): 169–180, 188.
CAI Danfeng, HU Qiuguang, WEI Xinyi. Extraction and management of coastal aquaculture ponds in Zhejiang Province based on Sentinel - 1 images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 169 – 180, 188. (in Chinese)