

doi:10.6041/j.issn.1000-1298.2025.05.009

# 基于光谱波段-纹理特征-植被指数融合的棉蚜虫危害等级无人机监测研究

廖娟<sup>1,2</sup> 王辉<sup>1,2</sup> 梁业雄<sup>1,2</sup> 何欣颖<sup>1,2</sup>  
曾浩求<sup>1,2</sup> 何松炜<sup>1,2</sup> 唐赛欧<sup>1,2</sup> 罗锡文<sup>1,3</sup>

(1. 华南农业大学工程学院, 广州 510642; 2. 华南农业大学南方农业机械与装备关键技术教育部重点实验室, 广州 510642;  
3. 广东省农业人工智能重点实验室, 广州 510642)

**摘要:** 棉蚜虫的精准无损检测对棉蚜虫害防治及棉花产量和品质的提升具有重要意义。本研究提出一种基于多特征融合的棉蚜虫危害等级(Cotton aphid damage levels, CADL)监测方法, 融合棉花冠层光谱特征波长、植被指数和纹理特征, 提高棉花蚜虫危害等级识别精度。采用无人机搭载高光谱成像系统采集棉花冠层高光谱图像, 利用 Savitzky-Golay 平滑(SG 平滑)和多元散射校正(MSC)对提取的光谱数据进行预处理, 利用支持向量机(SVM)模型将预处理后的光谱数据进行建模, 对比发现 MSC 表现更优。采用竞争性自适应重加权算法(CARS)和随机蛙跳算法(SFLA)对 MSC 预处理后的光谱数据进行特征波长一次提取, 分别提取出 31、37 个特征波长。进一步使用连续投影算法(SPA)对特征波长进行二次提取, 最终确定了 6 个棉蚜虫危害敏感波长, 分别为 650、786、931、938、945、961 nm。基于二次提取的 6 个特征波长, 计算了 9 种植被指数和 8 种纹理特征, 并分别分析了 9 种植被指数和 8 种纹理特征与棉蚜虫危害等级(CADL)的相关性。构建了 LightGBM、XGBoost、SVM 和 RF 模型, 并基于以上模型对比了特征波长、植被指数、纹理特征, 特征波长和植被指数 2 种特征相融合, 以及特征波长、植被指数和纹理特征 3 种特征相融合对棉蚜虫危害等级的判定效果。结果表明, 植被指数(RDVI、SAVI、MSAVI、OSAVI)和纹理特征(MEA、VAR、DIS、HOM)与 CADL 相关性较高。基于特征波长、植被指数和纹理特征 3 种特征相融合的 XGBoost 模型对棉蚜虫危害等级判定效果最佳, 测试集总体分类精度(OA)达到 86.99%, Kappa 系数为 0.8371, 相较于仅使用特征波长、植被指数、纹理特征, 特征波长和植被指数 2 种特征相融合的模型, 测试集 OA 分别提升 4.88、27.64、21.95、2.44 个百分点。

**关键词:** 棉蚜虫危害等级; 航空遥感; 高光谱; 纹理特征; 多特征融合

中图分类号: S127 文献标识码: A 文章编号: 1000-1298(2025)05-0091-12 OSID: 

## UAV Monitoring of Cotton Aphid Damage Levels Based on Fusion of Spectral Bands, Texture Features and Vegetation Indices

LIAO Juan<sup>1,2</sup> WANG Hui<sup>1,2</sup> LIANG Yexiong<sup>1,2</sup> HE Xinying<sup>1,2</sup> ZENG Haoqiu<sup>1,2</sup>  
HE Songwei<sup>1,2</sup> TANG Saiou<sup>1,2</sup> LUO Xiwen<sup>1,3</sup>

(1. College of Engineering, South China Agricultural University, Guangzhou 510642, China

2. Key Laboratory of Key Technology on Agricultural Machine and Equipment,

Ministry of Education, South China Agricultural University, Guangzhou 510642, China

3. Guangdong Provincial Key Laboratory of Agricultural Artificial Intelligence (GDKL-AAI), Guangzhou 510642, China)

**Abstract:** Accurate and nondestructive detection of cotton aphids is crucial for effective pest control and enhancing cotton yield and quality. Aiming to propose a multi-feature fusion method for cotton aphid damage level (CADL) monitoring, spectral feature wavelengths, vegetation indices, and cotton canopy texture characteristics were integrated to enhance the accuracy of cotton aphid damage level determination. A UAV-mounted hyperspectral imaging system was employed to collect hyperspectral image data of cotton canopy. Pre-processing of the extracted spectral data involved Savitzky-Golay smoothing (SG smoothing) and multiple scattering correction (MSC). Support vector machine (SVM)

收稿日期: 2025-02-27 修回日期: 2025-03-16

基金项目: 国家重点研发计划项目(2022YFD0202400)、兵团财政科技计划项目(2023AB014)和国家自然科学基金项目(31901401)

作者简介: 廖娟(1987—), 女, 助理研究员, 博士, 主要从事精准农业关键技术研究, E-mail: liaojuan0529@scau.edu.cn

通信作者: 罗锡文(1945—), 男, 教授, 中国工程院院士, 主要从事农业工程技术研究, E-mail: xwluo@scau.edu.cn

modeling was applied to the pre-processed spectral data, results revealed that MSC performed better than SG smoothing in pre-processing. Thus the spectral data pre-processed by MSC was used for characteristic wavelengths extraction. Characteristic wavelengths extraction was conducted by using the competitive adaptive reweighting algorithm (CARS) and the shuffled frog leaping algorithm (SFLA), totally 31 and 37 characteristic wavelengths were extracted by CARS and SFLA, respectively. Subsequently, the successive projections algorithm (SPA) was utilized for secondary characteristic wavelengths extraction. Ultimately, six sensitive wavelengths at wavelengths of 650 nm, 786 nm, 931 nm, 938 nm, 945 nm and 961 nm were extracted. Based on six secondarily extracted characteristic wavelengths, nine vegetation indices and eight texture features were calculated, followed by correlation analysis between these vegetation indices/texture features and CADL. Four machine learning models (LightGBM, XGBoost, SVM, RF) were developed to evaluate the classification performance by using characteristic wavelengths alone, vegetation indices alone, texture features alone, combined characteristic wavelengths and vegetation indices, and integrated characteristic wavelengths, vegetation indices, and texture features. Results indicated that vegetation indices (RDVI, SAVI, MSAVI, OSAVI) and texture features (MEA, VAR, DIS, HOM) exhibited strong correlations with CADL. The XGBoost model incorporating the tri-feature combination (characteristic wavelengths, vegetation indices, texture features) achieved optimal CADL classification performance, yielding an overall accuracy (OA) of 86.99% and a Kappa coefficient of 0.8371 on the test set. Compared with models by using characteristic wavelengths alone, vegetation indices alone, texture features alone, or the dual-feature combination (characteristic wavelengths, vegetation indices), this integrated approach improved OA by 4.88, 27.64, 21.95, and 2.44 percentage points, respectively.

**Key words:** cotton aphid damage levels; aerial remote sensing; hyperspectral; texture feature; multi-feature fusion

## 0 引言

棉花是世界上主要农作物之一,在生长过程中易受病虫害侵扰,严重影响其产量和品质<sup>[1]</sup>。据统计,1991—2010年由于棉花虫害发生强度增加15.9%,由虫害造成的棉花损失量增长22.4%<sup>[2]</sup>。棉蚜虫是棉花的主要虫害之一,繁殖迅速、数量庞大,严重危害棉花产量和质量<sup>[3]</sup>。目前,棉蚜虫的监测仍主要采用人工通过观察判定棉蚜虫的危害程度,并根据经验预测爆发的可能性<sup>[4]</sup>,这些观察结果可为后续的植保防控工作提供依据,但这种方法在效率和准确性上存在局限。实现棉蚜虫的精准和无损检测,对有效防治棉蚜虫及提高棉花产量具有重要意义。

近年来,基于无人机的低空遥感监测技术被广泛应用于植物病虫害监测<sup>[5]</sup>,其以精准、无损、使用灵活等特点被广泛应用于作物病虫害监测<sup>[6]</sup>。文献[7-13]研究表明,基于无人机的低空遥感监测技术是作物病虫害检测的有效方法。然而,仅依赖无人机图像的光谱信息(特征波长、植被指数)或纹理特征来监测作物病虫害,未能充分发挥无人机遥感图像的潜力。已有研究表明,当作物冠层覆盖度较大时,光谱信息容易出现饱和现象,造成信息丢失,从而影响监测精度;将光谱信息与图像纹理特征相融合,能够有效表征作物冠层结构的变化,可以在一定程度上弥补这一饱和问题对监测精度的影响<sup>[14-16]</sup>。

本研究以棉花为研究对象,通过提取无人机获取的高光谱图像中的特征波长、植被指数和纹理特征,分别基于特征波长、植被指数、纹理特征,特征波长和植被指数2种特征相融合,以及特征波长、植被指数和纹理特征3种特征相融合数据集,构建5种棉蚜虫害预测模型。通过数据融合,提高棉蚜虫危害等级监测精度,为棉蚜虫精准无损检测提供一种可靠方法,从而为有效防治棉蚜虫提供理论依据。

## 1 材料与方法

### 1.1 试验地点及试验小区设计

试验地点位于新疆维吾尔自治区石河子市石河子大学实验场二连(44°18'48"N, 85°59'52"E),如图1所示。试验区总长度25 m,总宽度17 m,共种植8个条带,每个条带种植35垄棉花,垄间距0.5 m,每5垄作为一个试验小区,共56个试验小区。试验棉花品种为新陆早四十八号,采用水肥管理方式,同时使用膜下灌溉栽培模式,棉蚜虫是该试验地主要的棉花虫害。

### 1.2 无人机高光谱数据采集

通过无人机搭载高光谱成像系统获取高光谱图像数据。其中,无人机平台是DJI Matrice 350 RTK型四旋翼无人机,含双电池空机质量约为6.47 kg,最大起飞质量为9.2 kg,最大水平飞行速度为23 m/s。高光谱设备是由Headwall公司生产的Nano HP推

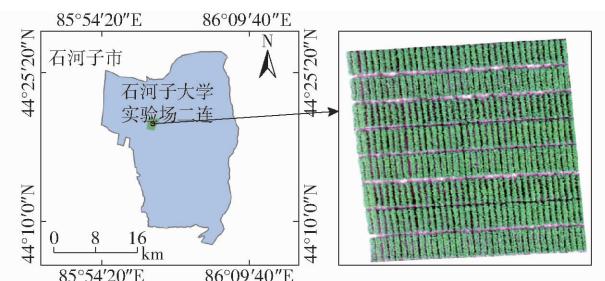


图1 试验区位置图

Fig. 1 Location map of experimental area

扫式微型机载高光谱成像仪,光谱波段为400~1 000 nm,光谱通道数为340,空间像素数为1 020,像元分辨率为4.88 cm,最大帧频率为250 f/s,镜头焦距为17 mm,总存储容量为480 GB,内部集成有采集控制模块和IMU模块。

无人机高光谱数据采集时间为2024年7月3、5、7、8、9、11日,棉花处于伏蚜期,选取棉蚜虫危害程度较高的区域进行采集,根据设定的航线飞行(图2)。数据采集在晴天、少云、无强风且光线充足的条件下进行,飞行时间设定为12:00—15:00,飞行高度为50 m,飞行速度为3~4 m/s,航向和旁向重叠率为30%和10%,采集数据期间未使用任何抑制蚜虫生长的农药。

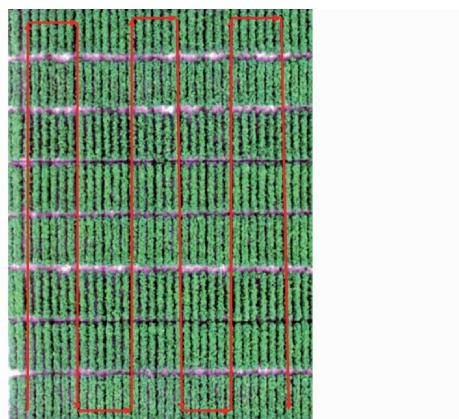


图2 无人机高光谱数据采集航线示意图

Fig. 2 Schematic of UAV hyperspectral data acquisition route

### 1.3 蚜害地面数据采集

利用无人机获取高光谱图像的同时,采用人工监测的方式同步监测56个小区的棉蚜虫危害等级(Cotton aphid damage levels, CADL)。依据国家标准(GB/T 22101.2—2009)棉花抗病虫性评价技术规范,每个小区随机调查50株棉花,以棉株顶部5片叶中受害最严重的叶片为标准叶,不同棉蚜虫危害等级叶片如图3所示,按照蚜害分级标准(表1)计算每个试验小区的蚜害指数,并根据蚜害指数确定该试验小区的危害等级(表2)。蚜害指数是一个综合指标,全面考虑植被的虫害率与危害程度,是评估植被蚜害信息的重要依据。蚜害指数*i*计算公式为

$$i = \frac{\sum d_c n_c}{4n_t} \quad (1)$$

式中  $d_c$ ——蚜害等级

$n_c$ ——该蚜害等级对应的棉花株数

$n_t$ ——总调查棉花株数

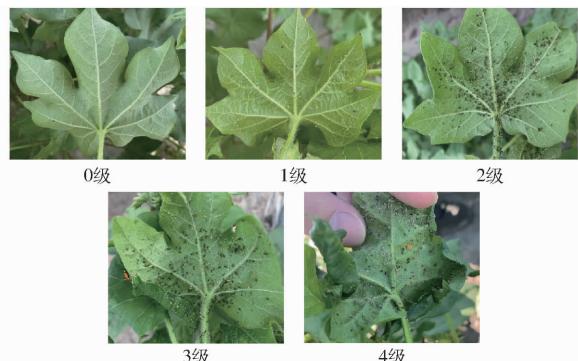


图3 不同棉蚜虫危害等级叶片图像

Fig. 3 Leaves of different cotton aphid damage levels

表1 棉蚜虫危害等级分类标准

Tab. 1 Classification standard for cotton aphid damage levels

蚜害等级	标准
0	无蚜虫,叶片平展
1	有蚜虫,叶片无受害
2	有蚜虫,受害最重的叶片皱缩或微卷
3	有蚜虫,受害最重的叶片卷曲达半圆或半圆以上,呈弧形
4	有蚜虫,受害最重的叶片完全卷曲,呈球状

表2 试验小区危害程度分类标准

Tab. 2 Standard for classification of harm degree in experimental plot

小区级别	危害程度	蚜害指数 <i>i</i>
S0	健康	0
S1	轻度	(0, 0.25]
S2	中度	(0.25, 0.50]
S3	偏重	(0.50, 0.75]
S4	重度	(0.75, 1]

### 1.4 数据处理方法

#### 1.4.1 光谱反射率信息提取

在无人机高光谱遥感数据采集过程中,受大气折射效应、地表高程变化等环境因素干扰,原始影像常出现几何畸变与辐射偏差。为确保后续分析的准确性,采用Headwall SpectralView专业图像处理平台,对试验区获取的原始高光谱数据进行预处理:首先通过辐射校正消除大气散射及光照条件差异,继而运用特征匹配算法完成几何校正,最终获取符合要求的高精度无人机高光谱影像数据。利用ENVI 5.6软件对校正后的无人机高光谱图像进行拼接。使用ENVI 5.6软件对拼接后的无人机高光谱图像进行分析,裁剪56个试验小区的高光谱图像。选取

试验小区范围内棉花冠层感兴趣区域(Region of interest, ROI)的平均反射光谱,作为该试验小区的光谱反射率。累计获得614个数据样本,按比例8:2划分训练集与测试集,即491个样本用于模型训练,123个样本用于性能评估,具体数据集划分结果如表3所示。

表3 数据集划分结果

Tab. 3 Division results of dataset

数据集	蚜害等级					总计
	0	1	2	3	4	
训练集	98	103	97	101	92	491
测试集	27	27	24	24	21	123
总计	125	130	121	125	113	614

#### 1.4.2 光谱数据预处理

在高光谱成像仪的采集过程中,外部环境的干扰、设备本身以及人员操作等,可能会导致高光谱数据受到基线漂移、散射光、噪声等因素的影响,从而使高光谱影像质量下降<sup>[17]</sup>。因此,为有效克服上述干扰因素并构建具备良好稳定性的预测模型,需对原始高光谱信息实施预处理操作。本研究分别运用Savitzky-Golay平滑算法(SG平滑)与多元散射校正(Multiplicative scatter correction, MSC)对采集的光谱数据进行预处理,提升光谱数据的可信度与测量精度。SG平滑是基于多项式拟合的方法对光谱数据进行平滑处理,在保留数据主要特征的同时消除随机噪声<sup>[18]</sup>。多元散射校正可以消除由于散射效应和颗粒大小差异引起的光谱基线漂移和幅度变化<sup>[19]</sup>,通过将测量的光谱校正到一个基准光谱上,减少与光谱数据无关的变化,从而提高光谱数据的准确性和可靠性。本文设置SG平滑,窗口大小为5,多项式阶数为3,导数为一阶导数。MSC使用输入数据的平均光谱作为校正的参考光谱。

#### 1.4.3 光谱特征波长提取

高光谱成像技术所获取的光谱数据呈现出显著的多维特性,海量数据规模以及波段间存在的显著相关性与冗余性,这些固有特征导致数据处理过程中面临计算复杂度高和运算效率受限的挑战。本研究采用特征波长优选策略对原始光谱进行降维处理,通过提取与样本属性高度相关的特征波长提升分析效率。采用竞争性自适应重加权采样法<sup>[20]</sup>(Competitive adaptative reweighted sampling, CARS)、随机蛙跳优化算法<sup>[21]</sup>(Shuffled frog leaping algorithm, SFLA)进行特征波长提取,采用连续投影算法<sup>[22]</sup>(Successive projections algorithm, SPA)对特征波长进行二次提取。CARS算法基于PLS模型回

归系数的绝对值分布特征,通过蒙特卡洛采样与自适应加权机制迭代优化波长子集,采用交叉验证均方根误差(RMSECV)作为评价指标,最终确定最优变量组合。SFLA算法创新性地融合模因进化机制与群体智能策略,兼具参数设置简便、收敛速度快、全局寻优性能突出等优势。SPA算法作为前向选择模型,通过最小化光谱向量共线性实现特征优化:首先随机选定初始波长,通过向量投影分析筛选共线性最小化的波段,构建多元线性回归模型后以均方根误差为判据确定最优特征组合。本研究设置CARS算法的蒙特卡洛采样次数为50,交叉验证次数为5。设置SFLA算法的蛙群数量为10,最大迭代次数为50,交叉验证次数为5。

#### 1.4.4 植被指数选取

植被指数(Vegetation index, VIs)是根据植被的光谱特性,将可见光和近红外波段进行组合形成的指数,植被指数的设计旨在增强植被光学特性对冠层总光谱响应的贡献。选取植物病虫害监测效果较好的9种植被指数,其计算公式如表4所示。

表4 植被指数及其计算公式

Tab. 4 Vegetation index and its calculation formula

植被指数	计算公式
归一化差异植被指数 (NDVI) <sup>[23]</sup>	$(NIR - R) / \sqrt{NIR + R}$
比值植被指数 (RVI) <sup>[24]</sup>	$NIR / R$
土壤调节植被指数 (SAVI) <sup>[25]</sup>	$1.5(NIR - R) / (NIR + R + 0.5)$
宽动态范围植被指数 (WDRVI) <sup>[25]</sup>	$(0.2NIR - R) / (0.2NIR + R)$
改进型简单比率指数 (MSR) <sup>[26]</sup>	$(NIR/R - 1) / \sqrt{NIR/R + 1}$
改进型土壤调节植被指数(MSAVI) <sup>[26]</sup>	$2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - R)} / 2$
红外简单比率指数 (ISR) <sup>[27]</sup>	$R/NIR$
归一化植被指数 (NDVI) <sup>[27]</sup>	$(NIR - R) / (NIR + R)$
优化土壤调节植被指数(OSAVI) <sup>[28]</sup>	$(NIR - R) / (NIR + R + 0.16)$

#### 1.4.5 纹理特征提取

纹理特征(Textural features, TFs)从图像中计算出来,用于量化区域内部灰度级变化的特征。基于灰度共生矩阵(Gray level co-occurrence matrix, GLCM<sup>[10]</sup>)提取每个试验小区的棉花冠层纹理特征,分别选择8类纹理特征:均值(Mean, MEA)、协方差(Variance, VAR)、同质性(Homogeneity, HOM)、对比度(Contrast, CON)、非相似性(Dissimilarity, DIS)、熵(Entropy, ENT)、角阶矩(Angular secondmoment,

ASM) 和相关性 (Correlation, COR)。选取窗口尺寸为  $7 \times 7$ , 计算方向  $45^\circ$  来计算。

## 1.5 数据融合方法

本研究提出的分类模型结合 3 种特征: 特征波长、植被指数和纹理特征。在特征层面对这些信息进行整合, 这种方法能将不同来源的数据有效结合。具体来说, 特征波长保留了作物反射光谱的核心特性, 植被指数增强了作物区域的生长状态信息, 纹理特征则捕捉了叶片表面的细节变化。为方便模型使用纹理特征, 把这些空间信息转化为具体数值。为消除不同特征之间的量纲差异, 对 3 种特征分别进行标准化处理。将标准化后的特征拼接在一起, 形成一个综合的高维特征组合<sup>[29]</sup>, 如图 4 所示。这种方法通过融合不同类型的信息, 既能提升特征的互补性, 又保持了模型对新数据的适应能力。

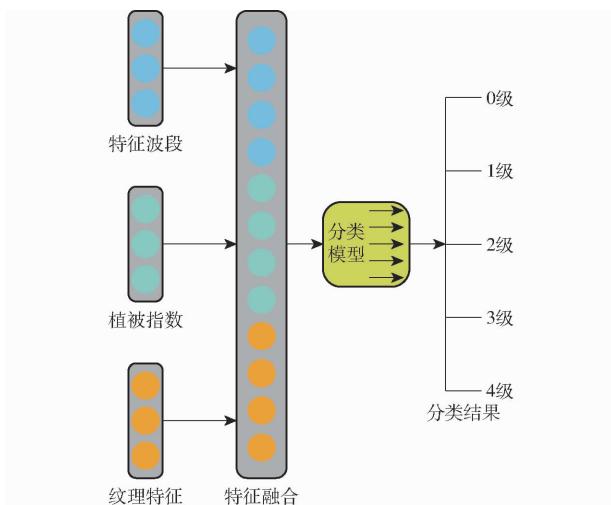


图 4 棉蚜虫危害等级多特征融合框图

Fig. 4 Multi-feature fusion block diagram of cotton aphid damage levels

## 1.6 模型建立

### 1.6.1 LightGBM

LightGBM 模型基于梯度提升框架, 通过集成多个弱学习器构建强学习器。其核心机制在于采用前向分步算法, 以累加方式结合各基学习器的预测结果, 并通过迭代优化过程逐步降低损失函数的期望值, 最终实现目标函数的最小化<sup>[30]</sup>。该算法的预测输出  $\hat{y}_i$  可表示为基学习器预测值的加权和, 即

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (f_k \in F) \quad (2)$$

式中  $K$ —基学习器总数

$x_i$ —1 条数据记录

$f_k$ —1 个基学习器

$f_k(x_i)$ —第  $K$  个基学习器对  $x_i$  的预测输出

$F$ —决策树的假设空间

通过最小化正则化损失函数, 即

$$L = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (3)$$

式中  $n$ —训练样本总数

$l(y_i, \hat{y}_i)$ —单个样本的损失函数

$\Omega(f_k)$ —第  $K$  个基学习器的正则化惩罚项

算法在每轮迭代中新增最优基学习器, 直至达到预设终止条件。这种基于直方图的决策树算法, 通过特征并行化和垂直生长策略, 显著提升了训练效率与内存利用率。本研究建立 LightGBM 模型时, 设定迭代次数为 50、学习率为 0.03、叶子数为 17、最大深度为 3。

### 1.6.2 XGBoost

XGBoost 通过线性叠加多个弱分类器的预测结果实现强学习器的构建<sup>[31]</sup>。该模型在工程实现层面具有显著优势, 其并行化设计使得训练效率显著提升, 同时在各类预测任务中展现出卓越的泛化能力。其核心机制在于迭代式特征分裂过程: 通过建立回归树序列不断修正前一阶段的预测误差, 在梯度下降方向上优化模型参数。当完成训练迭代后, 各基学习器的叶节点将生成对应的数值权重, 最终预测结果通过加权集成策略对全体基学习器的输出进行非线性组合得出。本研究建立 XGBoost 模型时, 设定学习率为 0.01、树的数量为 50、树的最大深度为 3。

### 1.6.3 支持向量机

支持向量机 (SVM) 是一种监督学习算法, 常用作广义线性分类器来解决二元分类问题<sup>[32]</sup>。支持向量机 (SVM) 本质在于构建  $n$  维特征空间中的最优决策超平面, 该超平面需满足正负样本间隔最大化的几何条件。对于非线性可分样本集, 该算法通过核技巧将原始数据投影到高维希尔伯特空间, 在此重构的线性可分空间内求解全局最优分类边界。正则化参数  $C$  作为模型复杂度的调节器, 控制着训练误差与结构风险的平衡关系。径向基核函数中的  $g$  参数则通过调控高斯函数的衰减速率, 直接影响样本点在特征空间中的相似性度量。本研究采用基于径向基核函数 (RBF) 的 SVM 架构, 通过穷举法遍历参数空间, 结合五折交叉验证的模型评估机制, 实现  $C-g$  双参数的协同优化, 最终确立具有最佳泛化性能的超参数组合。

### 1.6.4 随机森林

随机森林 (Random forest, RF) 核心思想是通过构建多棵决策树形成分类器集合。在模型训练过程中, 各基分类器采用自抽样方法从原始数据集中有放回地抽取训练子集<sup>[33]</sup>。该算法在预测阶段采用

多数表决原则整合各决策树的输出结果,这种集成策略不仅使模型对噪声数据具有较高容忍度,同时通过构建多样性基分类器有效抑制过拟合现象。本研究建立RF模型时,设定决策树数量为50。

## 1.7 评价指标

采用测试集的总体分类精度(Overall accuracy, OA)、Kappa系数和混淆矩阵作为模型评估标准。OA表示分类正确的样本占测试集总样本的比例,Kappa系数用于衡量预测结果与实际分类结果的一致性,混淆矩阵以真实类别每行的方向进行分析,当同时满足对角线数值最大化且非对角线数值总和最小化时,表示该类别分类效果最好。

## 2 结果与讨论

### 2.1 不同蚜害等级棉花冠层平均反射率

如图5所示,0~4级的平均光谱曲线整体走势相似,由于棉花叶片受到棉花蚜虫侵染后,叶片叶绿素和细胞结构受损,4级蚜害的棉花冠层在可见光波段(450~670 nm)中的平均光谱反射率高于健康棉花,且在绿光波段(约545 nm)出现明显高峰。在670~760 nm范围内,不同等级蚜害的平均光谱反射率呈上升趋势,并在近红外波段(760~930 nm)形成反射平台。0级健康棉花的平均光谱反射率在近红外波段最高,随着蚜害等级(1~4)增加,平均光谱反射率逐渐下降,该现象与郭伟等<sup>[7]</sup>在不同蚜害严重度的棉花冠层光谱曲线特征中观察到的现象一致,进一步认为,由于棉花蚜虫导致棉花叶片细胞受损,含水量降低,从而降低了近红外波段的平均光谱反射率。

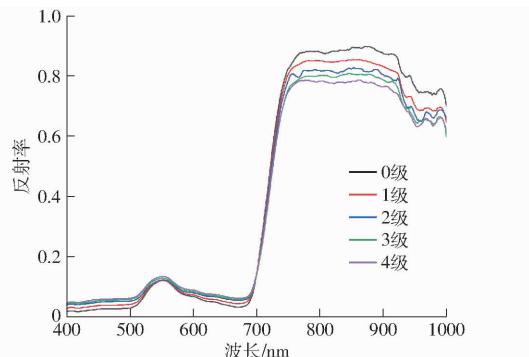


图5 不同蚜害等级棉花冠层的平均光谱反射率

Fig. 5 Average spectral reflectance of cotton canopies at different aphid infestation levels

### 2.2 数据预处理结果

将提取到的全波段光谱数据,采用SG平滑和MSC进行预处理,并将预处理后的数据导入支持向量机(SVM)分类器进行建模分析,模型性能评估结果见表5。通过对SG平滑和MSC构建的模型分类结果发现,经MSC处理的数据在SVM模型下测试集

OA为67.48%,Kappa系数为0.5912,在OA和Kappa系数方面均优于SG平滑法。其中,OA提升4.88个百分点,Kappa系数提升0.0621。后续特征波长提取和建模均基于MSC预处理的数据进行。

表5 全波段光谱数据建模结果

Tab. 5 Modeling results of full band spectral data

预处理方法	模型	训练集		测试集	
		OA/%	Kappa系数	OA/%	Kappa系数
SG平滑	SVM	66.53	0.5813	62.60	0.5291
MSC	SVM	70.41	0.6301	67.48	0.5912

在数据预处理阶段,刘潭等<sup>[34]</sup>采用SG平滑进行数据预处理,而本研究采用了两种常见的预处理方法SG平滑和MSC。结果表明,在去除基线漂移、消除散射光影响和改善数据一致性方面表现更为优越。SG平滑虽能够平滑噪声,但在复杂环境条件下除散射光影响仍有不足。经MSC处理后,数据的稳定性和一致性得到提升,提高了后续分析的可靠性。

### 2.3 特征波长提取结果

#### 2.3.1 基于CARS、SFLA的特征波长提取

CARS算法最终选择出31个特征波长,如图6a所示,CARS算法提取的特征波长主要分布于550~800 nm、900~1 000 nm。SFLA算法最终选择出

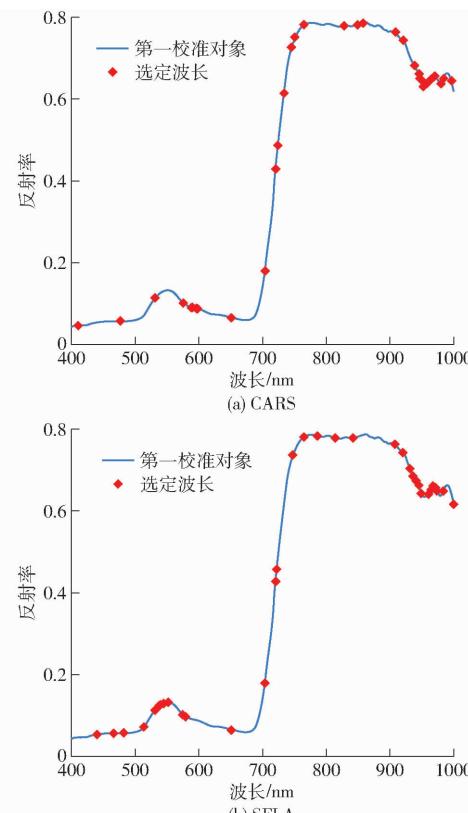


图6 不同特征提取算法提取特征波长

Fig. 6 Feature band extracted by different feature extraction algorithms

37 个特征波长, 如图 6b 所示, SFLA 算法提取的特征波长主要分布于 400~550 nm、650~950 nm。

### 2.3.2 基于一次提取特征波长的棉蚜虫害预测模型

对 CARS、SFLA 所选特征波长进行 LightGBM、XGBoost、SVM 和 RF 建模。由表 6 可见, LightGBM 和 XGBoost 模型棉蚜虫害预测精度优于 SVM、RF 模型。

表 6 一次提取特征波长建模结果

Tab. 6 Feature band modeling results extracted at one time

特征提取方法	特征波长数量	模型	训练集		测试集	
			OA/%	Kappa系数	OA/%	Kappa系数
CARS	31	LightGBM	80.82	0.7604	78.86	0.7353
		XGBoost	82.86	0.7858	80.49	0.7553
		SVM	74.90	0.6860	72.36	0.6529
		RF	73.88	0.6732	70.73	0.6325
SFLA	37	LightGBM	82.04	0.7756	79.67	0.7453
		XGBoost	83.47	0.7953	82.11	0.7757
		SVM	74.49	0.6808	73.17	0.6631
		RF	77.55	0.7195	74.80	0.6841

在 LightGBM 和 XGBoost 模型中, 具有基于预排序的决策树算法的 XGBoost 模型表现较优, MSC-CARS-XGBoost 模型训练集和预测集的 OA 分别为 82.86% 和 80.49%, Kappa 系数分别为 0.7858 和 0.7553。MSC-SFLA-XGBoost 模型训练集和测试集 OA 分别为 83.47% 和 82.11%, Kappa 系数分别为 0.7953 和 0.7757。综合比较模型在训练集与测试集的预测结果, MSC-SFLA-XGBoost 模型表现最优, 在棉蚜虫害预测上具有较好的预测效果, 后续特征波长二次提取基于 MSC-SFLA 进行。

### 2.3.3 特征波长二次提取

由于 MSC-SFLA 提取出的特征波长仍较多, 使用 SPA 对数据进行二次提取。根据实际需要, 将 SPA 提取特征波长个数设定为 4~6 个, SFLA 所选波长中提取出 6 个特征波长, 如图 7 所示, 分别为 650、786、931、938、945、961 nm, 为方便表述记为 Red、Rd、Nir\_1、Nir\_2、Nir\_3、Nir\_4。

### 2.4 基于植被指数的棉蚜虫害预测模型

选择与棉蚜虫危害等级 (CADL) 相关性较高的特征波长 Nir\_3 和 Red 计算植被指数, 并将计算的植被指数与棉蚜虫危害等级 (CADL) 进行相关性分析, 结果如图 8 所示, 植被指数与棉蚜虫危害等级 (CADL) 均呈显著相关, 在所选的植被指数中 RDVI、SAVI、MSAVI 和 OSAVI 与棉蚜虫危害等级 (CADL) 相关性较高, 相关系数  $|r|$  分别为 0.609、0.592、0.541 和 0.551。由于植被指数与棉蚜虫危

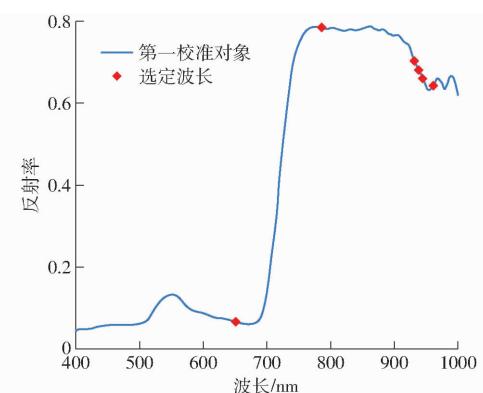


图 7 二次提取特征波长

Fig. 7 Feature band extracted twice

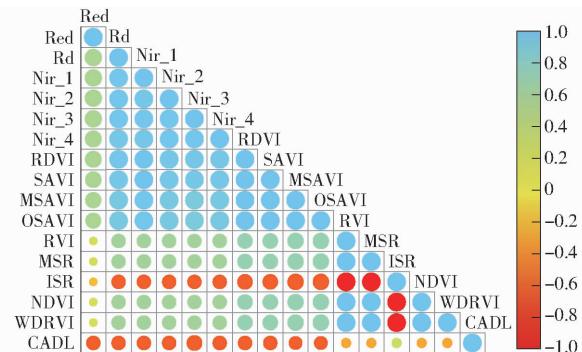


图 8 特征波长和植被指数与棉蚜虫危害等级相关性分析

Fig. 8 Analysis of correlation between feature bands and vegetation index and cotton aphid damage levels

害等级 (CADL) 均呈显著相关, 为避免数据产生冗余, 引入相关系数最高的 4 种植被指数 (RDVI、SAVI、MSAVI、OSAVI) 作为自变量, 构建 LightGBM、XGBoost、SVM 和 RF 的棉蚜虫害预测模型。基于植被指数的棉蚜虫害预测模型结果如表 7 所示, 在测试集上, LightGBM 模型展现出最优的分类性能, 其 OA 和 Kappa 系数分别达到 59.35% 与 0.4885。所有模型测试集 OA 介于 53.66%~59.35%, Kappa 为 0.4153~0.4885。上述结果表明, 植被指数能够提供一定的虫害识别信息, 但单独使用这类特征可能不足以有效区分不同虫害等级。

表 7 基于植被指数建模结果

Tab. 7 Modeling results based on vegetation index

模型	训练集		测试集	
	OA/%	Kappa 系数	OA/%	Kappa 系数
LightGBM	62.45	0.5302	59.35	0.4885
XGBoost	58.78	0.4839	56.91	0.4566
SVM	57.35	0.4658	55.28	0.4375
RF	54.49	0.4293	53.66	0.4153

### 2.5 基于纹理特征的棉蚜虫害预测模型

如图 8 所示, 选择与棉蚜虫危害等级 (CADL) 相关性最高的特征波长 Nir\_3 来提取纹理特征, 并

与棉蚜虫危害等级(CADL)进行相关性分析,相关性分析结果如图9所示。结果表明在选择的8种纹理特征中MEA、VAR、DIS和HOM相关性较高,相关系数分别为0.728、0.592、0.549和0.519,4个纹理特征可视化效果图如图10所示。选择与棉蚜虫危害等级(CADL)相关性最高的4种纹理特征(MEA、VAR、DIS、HOM)构建LightGBM、XGBoost、SVM和RF的棉蚜虫害预测模型。基于纹理特征的棉蚜虫害预测模型结果如表8所示,其中LightGBM模型在测试集上取得最高OA,为65.04%,相较于基于植被指数的LightGBM模型提升5.69个百分点,XGBoost模型在纹理特征下的测试集OA相较于在植被指数下的测试集OA提升7.32个百分点。结果表明,纹理特征在虫害识别中可能具有更优的

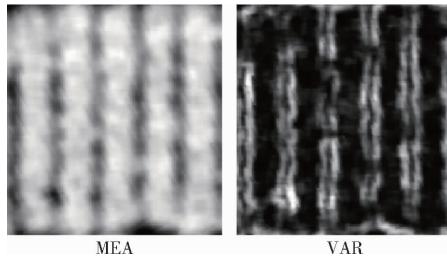


图10 纹理特征的可视化图像

Fig. 10 Visualization of texture features

表8 基于纹理特征建模结果

Tab. 8 Modeling results based on texture features

模型	训练集		测试集	
	OA/%	Kappa系数	OA/%	Kappa系数
LightGBM	66.73	0.5834	65.04	0.5606
XGBoost	67.76	0.5963	64.23	0.5506
SVM	61.84	0.5220	60.98	0.5090
RF	56.53	0.4560	54.47	0.4269

## 2.6 基于特征波长和植被指数融合的棉蚜虫害预测模型

选择相关系数 $|r|$ 最高的4种植被指数与特征波长进行融合,因此引入特征波长(Red、Rd、Nir\_1、Nir\_2、Nir\_3、Nir\_4)和植被指数(RDVI、SAVI、MSAVI、OSAVI)作为特征输入变量构建棉蚜虫害预测模型,结果如表9所示,将特征波长和植被指数融合作为输入变量构建的棉蚜虫害预测模型在精度上有所提高,LightGBM模型表现最佳,测试集中,LightGBM模型OA为84.55%,Kappa系数为0.8067,相比于基于植被指数的LightGBM模型,OA提升25.20个百分点,Kappa系数提升0.3182。结果表明,将特征波长和植被指数融合作为特征输入变量,相比于只使用植被指数作为特征输入变量,在棉蚜虫害预测精度上有所提升。

图11为特征波长和植被指数融合作为特征输

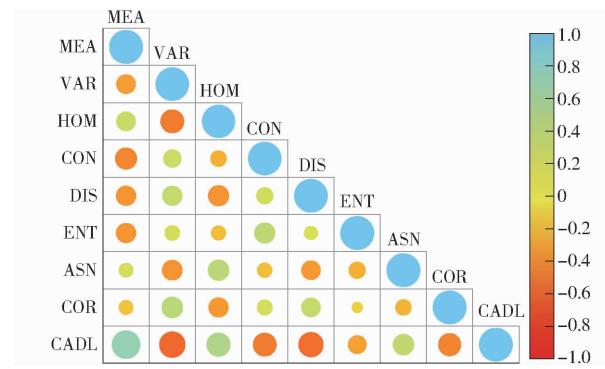


图9 纹理特征与棉蚜虫危害等级相关性分析

Fig. 9 Correlation analysis between texture characteristics and cotton aphid damage levels

鉴别潜力,但是所有模型的测试集OA仍介于54%~66%,分类性能尚不理想。

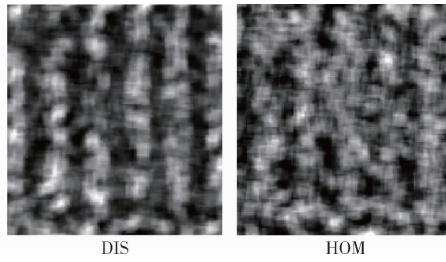


图10 纹理特征的可视化图像

表9 基于特征波长和植被指数融合建模结果

Tab. 9 Modeling results based on fusion of feature band and vegetation index

模型	训练集		测试集	
	OA/%	Kappa系数	OA/%	Kappa系数
LightGBM	87.55	0.8444	84.55	0.8067
XGBoost	85.31	0.8163	82.93	0.7860
SVM	79.59	0.7451	78.86	0.7354
RF	76.33	0.7043	75.61	0.6946

入变量构建的棉蚜虫害预测模型在测试集上的混淆矩阵,LightGBM模型共有19处错误分类,XGBoost模型共有21处错误分类,SVM模型共有26处错误分类,RF模型共有30处错误分类。对比4个混淆矩阵,可以得到LightGBM、XGBoost模型准确率较高。其中SVM、RF模型在预测棉蚜虫害等级上均有较大的错分情况,在3级上错分样本数量最多,分别为13个和15个,LightGBM和XGBoost模型在3级上错分样本数量较少,分别为6个和8个。而所有模型在0级上分类准确率最高,原因可能是棉花叶片在受到轻度虫害时,棉花冠层的光谱特性会有较明显变化,从而导致模型对有无虫害分类准确率较高。

## 2.7 基于特征波长、植被指数和纹理特征融合的棉蚜虫害预测模型

基于特征波长和植被指数融合的棉蚜虫害预测

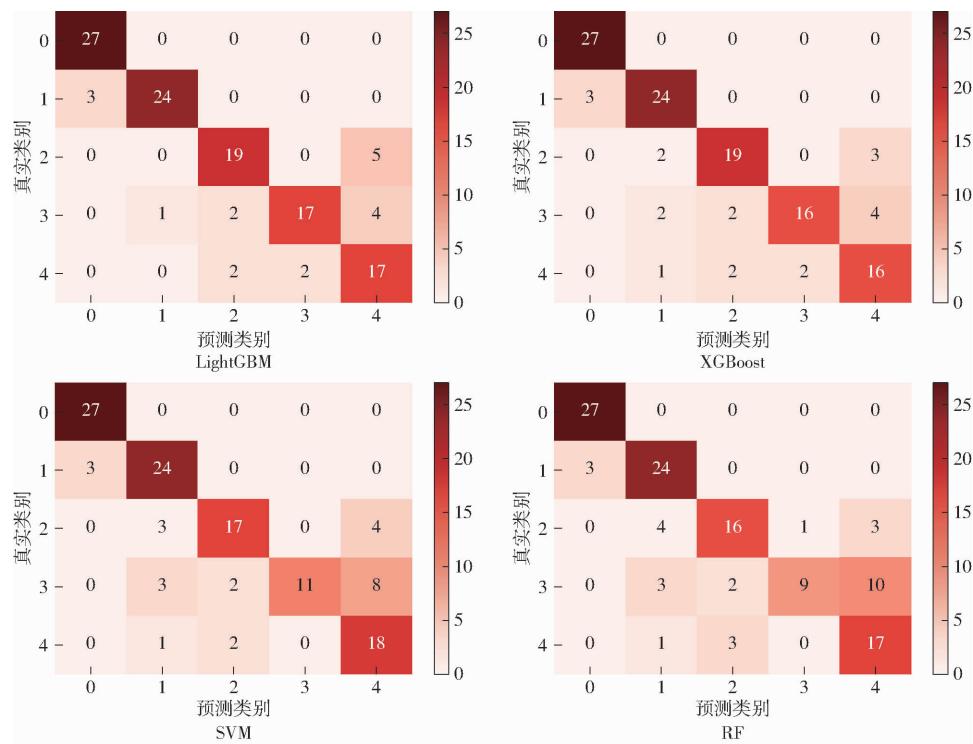


图 11 特征波长和植被指数融合模型测试集混淆矩阵

Fig. 11 Feature band and vegetation index fusion model test set confusion matrix

模型在预测精度上仍有不足, 分别选择相关系数绝对值最高的 4 种植被指数和 4 种纹理特征与特征波长进行融合, 故引入特征波长 (Red、Rd、Nir\_1、Nir\_2、Nir\_3、Nir\_4)、植被指数 (RDVI、SAVI、MSAVI、OSAVI) 和纹理特征 (MEA、VAR、DIS、HOM) 作为特征输入变量构建棉蚜虫害预测模型。模型预测结果如表 10 所示, 在测试集中, XGBoost、LightGBM 模型 OA 分别为 86.99% 和 85.37%, Kappa 系数分别为 0.8371 和 0.8167, 相比于特征波长和植被指数融合作为输入变量构建的模型, OA 分别提升 4.06、0.82 个百分点, Kappa 系数分别提升 0.0511 和 0.01。结果表明, 光谱信息(特征波长和植被指数)融合纹理特征具有最佳的预测精度。

表 10 特征波长、植被指数和纹理特征融合建模结果

Tab. 10 Feature band and vegetation index and texture feature fusion modeling results

模型	训练集		测试集	
	OA/%	Kappa 系数	OA/%	Kappa 系数
LightGBM	87.14	0.8394	85.37	0.8167
XGBoost	88.16	0.8521	86.99	0.8371
SVM	80.82	0.7604	77.24	0.7146
RF	80.00	0.7501	76.42	0.7047

图 12 为光谱信息(特征波长和植被指数)融合纹理特征作为输入变量构建的棉蚜虫害预测模型在测试集上的混淆矩阵, LightGBM 模型共有 18 处错误分类, XGBoost 模型共有 16 处错误分类, SVM 模

型共有 28 处错误分类, RF 模型共有 29 处错误分类。对比 4 个混淆矩阵, 可以得到 XGBoost 模型准确率最佳。LightGBM 和 XGBoost 模型在 4 级上的错分样本数量相比于特征波长和植被指数融合构建的棉蚜虫害预测模型分别减少 2 个和 3 个, 具有较大的提升。结果表明, 棉花叶片受到重度虫害时, 叶片的粗糙度、纹路结构和颜色分布会发生较为明显的变化, 而融合纹理特征能够捕捉到叶片表面的变化, 从而更好地地区分出重度虫害与其它虫害等级。

本研究对不同的机器学习模型进行了比较, 评估其在高光谱数据分类中的表现。LightGBM 和 XGBoost 表现出了明显的优势。它们在训练集和测试集上的 OA 和 Kappa 系数均高于其他模型, 尤其是在测试集上, LightGBM 的 OA 为 85.37%, XGBoost 为 86.99%, 分别比 SVM 和 RF 模型高出 8、10 个百分点。这表明, 基于梯度提升树的模型能够更好地适应高维特征空间, 并通过有效的特征选择和建模技巧, 提升棉蚜虫害预测的准确性。许敬诚等<sup>[10]</sup>基于叶片纹理特征的棉蚜虫害诊断模型预测集识别率为 92.55%, 但其研究局限于实验室环境下的离体叶片分析, 而本研究通过无人机遥感实现了田间原位监测, 且融合光谱信息与纹理特征进一步提升了模型的泛化能力。然而, 由于数据集规模的限制, 模型的表现仍有提升空间。因此, 未来的研究可以考虑通过增加数据量来进一步研究对于模型精度的影响。

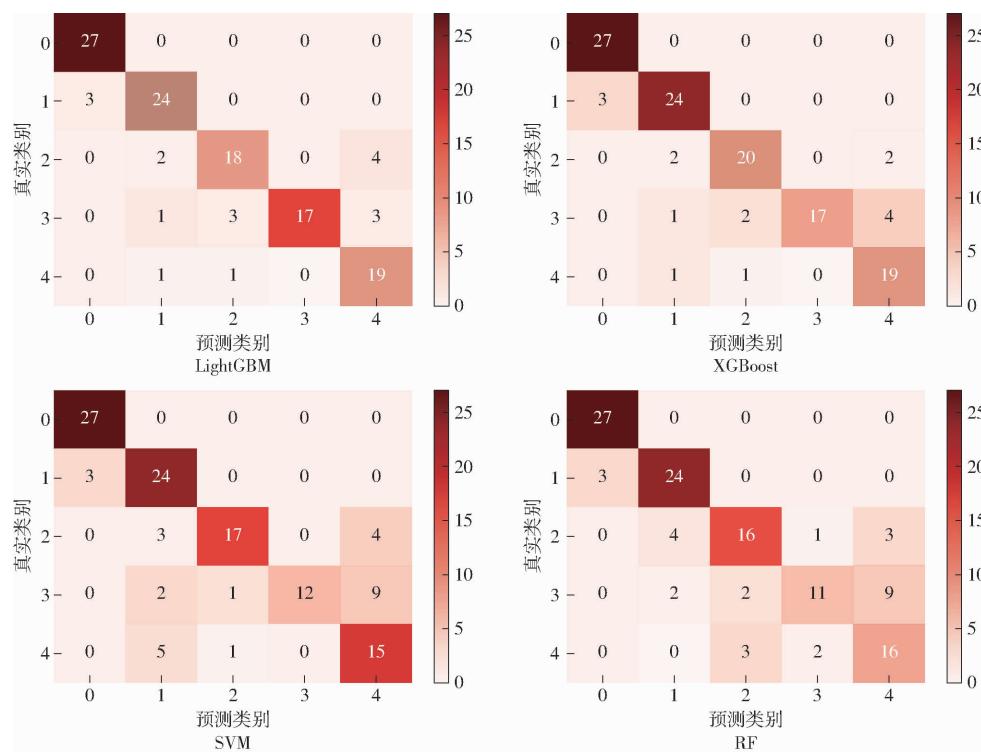


图 12 特征波长、植被指数和纹理特征融合模型测试集混淆矩阵

Fig. 12 Feature band, vegetation index and texture feature fusion model test set confusion matrix

在本研究中,光谱信息和纹理特征的融合在棉蚜虫害预测中显著提升了模型的分类性能。LightGBM 和 XGBoost 模型在 4 级(重度虫害)上的错分样本较少,分别减少 2 个和 3 个。单独使用光谱信息时,模型在较高冠层覆盖度或部分遮挡条件下的表现较差。然而,纹理特征的引入有效弥补了这一缺陷。这一结果表明,纹理特征能够有效捕捉到棉花叶片在遭受重度虫害时的性状变化,而这些变化是传统光谱波段和植被指数难以区分的。因此,纹理特征的引入使得模型在区分不同虫害等级时具有更高的精度,尤其是在识别重度虫害时表现尤为突出。芦兵等<sup>[35]</sup> 分别使用 LBP、GLCM 算法提取图像中的纹理特征,最终通过 ELM 建立预测分类模型。结果表明,LBP-ELM 预测模型性能最好,分类正确率为 85.45%。本研究仅使用 GLCM 算法来提取纹理特征,未来的研究可以进一步探讨选择不同的纹理特征提取算法和优化不同类型的纹理特征,以提升棉蚜虫监测的精度和可靠性。

本研究证明了无人机高光谱遥感技术在棉蚜虫害监测中的有效性,但在实际应用中仍面临一些挑战。首先,无人机飞行高度、速度和环境因素(如光照、天气等)对图像质量和数据获取有一定影响,需要在不同气候和地理条件下进一步验证其稳定性和适应性。其次,实时数据处理和模型部署仍是制约无人机遥感技术广泛应用的瓶颈,未来的研究可以

进一步探索实时数据分析技术。总体而言,基于无人机高光谱遥感的棉蚜虫害监测技术,能够为棉花病虫害防控提供重要的技术支持。未来的研究应聚焦于优化数据处理流程、提高模型的泛化能力,并解决现实应用中的技术挑战,推动这一技术在农业中的广泛应用。

### 3 结论

(1) 通过采用无人机高光谱遥感技术获取棉花高光谱图像,融合光谱特征波长、植被指数和纹理特征,研究了基于 3 种信息融合的棉蚜虫害等级监测。结果表明,利用无人机高光谱数据可以有效监测棉蚜虫危害程度,通过不同数据处理方法,能够有效提高棉蚜虫危害等级模型的准确性。

(2) 通过 MSC-SFLA 算法提取的 37 个特征波长构建的 XGBoost 模型表现最佳,测试集总体分类精度(OA)为 82.11%,Kappa 系数为 0.7757。表明光谱特征能够有效反映棉花冠层受蚜虫侵害后的反射特性变化,但单一光谱信息在高冠层覆盖条件下易出现光谱饱和问题。基于植被指数(RDVI、SAVI、MSAVI、OSAVI)的 LightGBM 模型测试集 OA 为 59.35%,Kappa 系数为 0.4885。植被指数虽与虫害等级显著相关,但因信息冗余和区分能力有限,单独应用时难以充分捕捉虫害的复杂特征。基于纹理特征(MEA、VAR、DIS、HOM)的 LightGBM 模型测试集 OA 为 65.04%,Kappa 系数为 0.5606。单独应用纹

理特征时对轻度虫害的敏感性较低,导致整体精度仍不理想。

(3)通过融合特征波长、植被指数与纹理特征构建的XGBoost模型表现最优,测试集OA达86.99%,Kappa系数为0.8371。相较于仅使用特征波长、植被指数、纹理特征,特征波长和植被指数2种特征相融合的模型,测试集OA分别提升4.88%、

27.64%、21.95%、2.44个百分点,可以看到多特征融合显著提高了分类精度。其优势体现在:光谱信息量化了冠层反射率变化,植被指数强化了植被生理响应特征,而纹理特征弥补了光谱饱和问题,通过捕捉叶片粗糙度与结构变化,有效提升了重度虫害的识别能力。结果表明,多特征融合能够协同增强模型对棉蚜虫害的判别能力。

## 参 考 文 献

- [1] 李磊,牟少敏,林中琦.随机森林在棉蚜虫害等级预测中的应用[J].安徽农学通报,2017,23(1):18~20.  
LI Lei, MOU Shaomin, LIN Zhongqi. Application of random forest in forecasting cotton aphid pest grade [J]. Anhui Agricultural Science Bulletin, 2017, 23(1): 18~20. (in Chinese)
- [2] 房雪,GE Saiying,张永生,等.1991—2010年中国棉花病虫害经济损失分析[J].应用昆虫学报,2014,51(4):1104~1113.  
FANG Xue, GE Saiying, ZHANG Yongsheng, et al. Analysis of economic loss from pest insects and plant disease in cotton of China during 1991—2000 [J]. Journal of Applied Entomology, 2014, 51(4): 1104~1113. (in Chinese)
- [3] 林皎,张家琪,候金枚,等.棉蚜虫情信息监测研究进展[J].安徽农业科学,2024,52(20):11~15.  
LIN Jiao, ZHANG Jiaqi, HOU Jinmei, et al. Research progress of aphids information monitoring [J]. Journal of Anhui Agricultural Sciences, 2024, 52(20): 11~15. (in Chinese)
- [4] 唐平华,陈国平,朱明库,等.蚜虫防治技术研究进展[J].植物保护,2013,39(2):5~12,19.  
TANG Pinghua, CHEN Guoping, ZHU Mingku, et al. Advances in aphid control technology [J]. Plant Protection, 2013, 39(2): 5~12,19. (in Chinese)
- [5] 曹英丽,张弘泽,郭福旭,等.基于无人机遥感的农作物病害监测研究进展[J].沈阳农业大学学报,2024,55(5):616~628.  
CAO Yingli, ZHANG Hongze, GUO Fuxu, et al. Research progress of crop disease monitoring based on UAV remote sensing [J]. Journal of Shenyang Agricultural University, 2024, 55(5): 616~628. (in Chinese)
- [6] 胡连槟,兰玉彬,于海琳,等.棉花病虫害遥感监测研究进展[J].山东农业科学,2024,56(4):164~171.  
HU Lianbin, LAN Yubin, YU Hailin, et al. Research progress on remote sensing monitoring of pests and diseases in cotton [J]. Shandong Agricultural Sciences, 2024, 56(4): 164~171. (in Chinese)
- [7] 郭伟,乔红波,赵恒谦,等.基于比值导数法的棉花蚜害无人机成像光谱监测模型研究[J].光谱学与光谱分析,2021,41(5):1543~1550.  
GUO Wei, QIAO Hongbo, ZHAO Hengqian, et al. Cotton aphid damage monitoring using UAV hyperspectral data based on derivative of ratio spectroscopy [J]. Spectroscopy and Spectral Analysis, 2021, 41(5): 1543~1550. (in Chinese)
- [8] 地力夏提·依马木,周建平,许燕,等.基于Logistic算法与遥感影像的棉花虫害监测研究[J].华南农业大学学报,2022,43(2):87~95.  
DILIXIATI Yimamu, ZHOU Jianping, XU Yan, et al. Cotton pest monitoring based on Logistic algorithm and remote sensing image [J]. Journal of South China Agricultural University, 2022, 43(2): 87~95. (in Chinese)
- [9] ZHAO R, ZHANG B, ZHANG C, et al. Goji disease and pest monitoring model based on unmanned aerial vehicle hyperspectral images [J]. Sensors, 2024, 24(20): 6739.
- [10] 许敬诚,吕新,林皎,等.基于叶片纹理特征的棉花蚜害诊断模型研究[J].棉花学报,2020,32(2):133~142.  
XU Jingcheng, LÜ Xin, LIN Jiao, et al. The diagnostic model of cotton aphids based on leaf textural features [J]. Cotton Science, 2020, 32(2): 133~142. (in Chinese)
- [11] 崔美娜,戴建国,王守会,等.基于无人机多光谱影像的棉叶螨识别方法[J].新疆农业科学,2018,55(8):1457~1466.  
CUI Meina, DAI Jianguo, WANG Shouhui, et al. Research on identification method of mite infection cotton based on UAV multi-spectral image [J]. Xinjiang Agricultural Sciences, 2018, 55(8): 1457~1466. (in Chinese)
- [12] JIANG X, ZHEN J, MIAO J, et al. Assessing mangrove leaf traits under different pest and disease severity with hyperspectral imaging spectroscopy [J]. Ecological Indicators, 2021, 129: 107901.
- [13] 冯子恒,宋莉,张少华,等.基于无人机多光谱和热红外影像信息融合的小麦白粉病监测[J].中国农业科学,2022,55(5):890~906.  
FENG Ziheng, SONG Li, ZHANG Shaohua, et al. Wheat powdery mildew monitoring based on information fusion of multi-spectral and thermal infrared images acquired with an unmanned aerial vehicle [J]. Scientia Agricultura Sinica, 2022, 55(5): 890~906. (in Chinese)
- [14] CEN H, WAN L, ZHU J, et al. Dynamic monitoring of biomass of rice under different nitrogen treatments using a lightweight UAV with dual image-frame snapshot cameras [J]. Plant Methods, 2019, 15: 1~16.
- [15] WAN L, LI Y, CEN H, et al. Combining UAV-based vegetation indices and image classification to estimate flower number in oilseed rape [J]. Remote Sensing, 2018, 10(9): 1484.
- [16] MAIMAITIJIANG M, GHULAM A, SIDIKE P, et al. Un-manned aerial system (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017: 134: 43~58.

- [17] 黄旭影,许章华,王小平,等.刚竹毒蛾危害下的毛竹叶片光谱特征及虫害等级检测研究[J].光谱学与光谱分析,2021,41(4):1253–1259.  
HUANG Xuying, XU Zhanghua, WANG Xiaoping, et al. Spectral characteristics of moso bamboo leaves damaged by *Pantana phyllostachysae* chao and monitoring of pest rating[J]. Spectroscopy and Spectral Analysis, 2021, 41(4): 1253–1259. (in Chinese)
- [18] 曹益飞,袁培森,王浩云,等.基于光谱分形维数的水稻白叶枯病害监测指数研究[J].农业机械学报,2021,52(9):134–140.  
CAO Yifei, YUAN Peisen, WANG Haoyun, et al. Monitoring index of rice bacterial blight based on hyperspectral fractal dimension[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(9): 134–140. (in Chinese)
- [19] 陈子涵,黄亮,温志强,等.基于高光谱成像技术的双孢蘑菇病害早期诊断[J].福建农业学报,2021,36(11):1365–1372.  
CHEN Zihan, HUANG Liang, WEN Zhiqiang, et al. Hyperspectral imaging technology-based early diagnosis of a serious *Agaricus bisporus* disease[J]. Fujian Journal of Agricultural Sciences, 2021, 36(11): 1365–1372. (in Chinese)
- [20] 霍迎秋,赵士超,赵国祺,等.基于无人机多光谱的猕猴桃园冠层叶绿素含量检测方法[J].农业机械学报,2024,55(9):297–307.  
HUO Yingqiu, ZHAO Shichao, ZHAO Guoqi, et al. Detection method of chlorophyll content in canopy of kiwifruit orchard based on UAV[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 297–307. (in Chinese)
- [21] 刘莉,陶红燕,方静,等.基于近红外高光谱的梨叶片炭疽病与黑斑病识别[J].农业机械学报,2022,53(2):221–230.  
LIU Li, TAO Hongyan, FANG Jing, et al. Identifying anthracnose and black spot of pear leaves on near-infrared hyperspectroscopy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53 (2): 221 – 230. ( in Chinese )
- [22] 张楠楠,张晓,王城坤,等.基于高光谱和连续投影算法的棉花叶面积指数估测[J].农业机械学报,2022,53(增刊1):257–262.  
ZHANG Nannan, ZHANG Xiao, WANG Chengkun, et al. Cotton LAI estimation based on hyperspectral and successive projection algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(Supp. 1): 257 – 262. ( in Chinese )
- [23] BUNKEI M, WEI Y, JIN C, et al. Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest[J]. Sensors, 2007, 7(11):2636–2651.
- [24] CONG W, JIN C, JIN W, et al. A snow-free vegetation index for improved monitoring of vegetation spring green-up date in deciduous ecosystems[J]. Remote Sensing of Environment, 2017, 196:1–12.
- [25] GITELSON A A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation[J]. Journal of Plant Physiology, 2004, 161(2):165 – 173.
- [26] ALATORRE L C, SANCHEZ-CARRILLO S, MIRAMONTES-BELTRAN S, et al. Temporal changes of NDVI for qualitative environmental assessment of mangroves: shrimp farming impact on the health decline of the arid mangroves in the Gulf of California(1990—2010)[J]. Journal of Arid Environments, 2016, 125(2):98 – 109.
- [27] ZENG Y, HAO D, BADGLEY G, et al. Estimating near-infrared reflectance of vegetation from hyperspectral data[J]. Remote Sensing of Environment, 2021, 267:112723.
- [28] HERRMANN S M, TAPPAN G G. Vegetation impoverishment despite greening: a case study from central Senegal[J]. Journal of Arid Environments, 2013, 90(3):55 – 66.
- [29] PETERSON K T, SAGAN V, SIDIKE P, et al. Machine learning-based ensemble prediction of water-quality variables using feature-level and decision-level fusion with proximal remote sensing[J]. Photogrammetric Engineering & Remote Sensing, 2019, 85(4): 269 – 280.
- [30] KE G, MENG Q, FINLEY T, et al. Lightgbm: a highly efficient gradient boosting decision tree[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 3149 – 3157.
- [31] YU B, QIU W, CHEN C, et al. SubMito-XGBoost: predicting protein submitochondrial localization by fusing multiple feature information and extreme gradient boosting[J]. Bioinformatics, 2020, 36(4): 1074 – 1081.
- [32] ABDULLAH D M, ABDULAZEEZ A M. Machine learning applications based on SVM classification a review[J]. Qubahan Academic Journal, 2021, 1(2): 81 – 90.
- [33] BELGIU M, DRĂGUȚ L. Random forest in remote sensing: a review of applications and future directions[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 114: 24 – 31.
- [34] 刘潭,李子默,冯帅,等.基于LMPSO-SVM的高光谱水稻稻瘟病害分级检测[J].农业机械学报,2023,54(11):208 – 216,235.  
LIU Tan, LI Zimo, FENG Shuai, et al. Classification detection of hyperspectral rice blast disease based on LMPSO – SVM [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 208 – 216,235. (in Chinese)
- [35] 芦兵,孙俊,杨宁,等.基于荧光透射谱和高光谱图像纹理的茶叶病害预测研究[J].光谱学与光谱分析,2019,39(8):2515 – 2521.  
LU Bing, SUN Jun, YANG Ning, et al. Prediction of tea diseases based on fluorescence transmission spectrum and texture of hyperspectral image[J]. Spectroscopy and Spectral Analysis, 2019, 39(8): 2515 – 2521. ( in Chinese )