doi:10.6041/j.issn.1000-1298.2026.03.010

基于多源特征融合的玉米大螟危害等级监测研究

焦乐宁[1,2]　刘家天[1,2]　李新龙[1,2]　刘海藤[1,2]　王国宾[1,2]　王会征[1,2]
（1.山东理工大学农业工程与食品科学学院，淄博 255000；2.山东理工大学生态无人农场研究院，淄博 255000）

摘要：大螟在玉米生长早期造成的茎秆破坏切断了水分和养分运输，该虫害无损精准检测技术的应用对优化防控策略、提升玉米生产效益具有显著性影响。本研究提出一种基于多源特征融合的玉米大螟危害等级（Asian corn borer damage levels，ACBDL）监测方法，融合玉米三叶期植被指数、纹理特征和颜色指数，构建玉米早期大螟危害等级监测模型，提高玉米大螟危害等级预测精度。利用无人机搭载的 RGB 及多光谱成像系统采集玉米三叶期光谱影像，采用监督分类中的马氏距离分类（Mahalanobis distance classification，MDC）将玉米与土壤进行分类，并进行二值化掩膜剔除土壤背景。提取过量绿色指数（Excess green index，ExG）和土壤调节植被指数（Soil-adjusted vegetation index，SAVI）等 14 种植被指数，基于灰度共生矩阵（Gray-level co-occurrence matrix，GLCM）计算 4 个波段共 32 种纹理特征，转化计算得到 8 种颜色特征参数。采用皮尔逊相关系数法（Pearson correlation coefficient，PCC）筛选特征，构建机器学习模型随机森林（Random forest，RF）、极端梯度提升（Extreme gradient boosting，XGBoost）、K 最近邻（K-nearest neighbors，KNN）和类别提升（Categorical boosting，CatBoost）预测模型。结果显示：多源特征融合可显著提高模型预测精度，KNN 模型在植被指数、纹理特征和颜色指数融合的条件下综合性能表现最优，总体准确率、精确率、召回率、F1 值和 Kappa 系数分别为 91.8%、91.9%、91.8%、89.5% 和 87.4%。该研究验证了多源特征融合在大螟危害等级预测中的有效性，为玉米早期病虫害防治提供可靠技术参考。

关键词：玉米大螟危害等级；无人机遥感；纹理特征；机器学习；多源特征融合
中图分类号：S127　　**文献标识码**：A　　**文章编号**：1000-1298(2026)03-0097-12　　**OSID**：

Monitoring of Asian Corn Borer Damage Levels Based on Multi-source Feature Fusion

JIAO Lening[1,2]　LIU Jiatian[1,2]　LI Xinlong[1,2]　LIU Haiteng[1,2]　WANG Guobin[1,2]　WANG Huizheng[1,2]
(1. *College of Agricultural Engineering and Food Science*, *Shandong University of Technology*, *Zibo* 255000, *China*
2. *Academy of Ecological Unmanned Farm*, *Shandong University of Technology*, *Zibo* 255000, *China*)

Abstract: The Asian corn borer causes stem damage in the early growth stage of maize, disrupting the transport of water and nutrients. The application of non-destructive and precise detection techniques is crucial for optimizing pest control strategies and improving maize production efficiency. A multi-source feature fusion-based method for monitoring the corn borer damage level (CBDL) was proposed, integrating vegetation indices, texture features, and color indices of maize at the three-leaf stage to enhance the overall accuracy of early-stage damage assessment. UAV-mounted RGB and multispectral imaging systems were employed to acquire spectral data during the three-leaf stage. The mahalanobis distance classification (MDC) algorithm under supervised classification was used to distinguish maize from soil, followed by binary masking to remove soil background. Fourteen vegetation indices, including the excess green index (ExG) and soil-adjusted vegetation index (SAVI) were extracted; totally 32 texture features were computed from four bands based on the gray-level co-occurrence matrix (GLCM); and eight color parameters were derived. Features were selected by using the Pearson correlation coefficient (PCC), and machine learning prediction models, including random forest (RF), extreme gradient boosting (XGBoost), K-nearest neighbors (KNN), and categorical boosting (CatBoost) were

收稿日期：2025-10-22　修回日期：2025-11-18
基金项目：国家重点研发计划项目（2024YFD2301100）和宁夏回族自治区重点研发计划项目（2023BCF01051、2024BBF01013）
作者简介：焦乐宁（2000—），男，硕士生，主要从事智慧农业关键技术研究，E-mail：2722754956@qq.com
通信作者：王会征（1984—），男，副教授，博士，主要从事精准农业航空应用技术研究，E-mail：hzwang@sdut.edu.cn

constructed. Results indicated that multi-source feature fusion significantly improved model prediction overall accuracy. Among all models, the KNN model integrating vegetation, texture, and color features achieved the best overall performance, with an overall accuracy, precision, recall, F1-score, and Kappa coefficient of 91.8%, 91.9%, 91.8%, 89.5%, and 87.4%, respectively. The findings demonstrated the effectiveness of multi-source feature fusion in predicting the damage level of corn borer infestations, and it can provide a reliable technical reference for early detection and control of maize pests.

Key words: Asian corn borer damage level; UAV remote sensing; texture features; machine learning; multi-source feature fusion

0 引言

玉米是我国重要的粮食作物,在人类食物供给与经济发展中具有不可替代的地位[1-2]。在其生长过程中极易遭受病虫害侵袭,从而严重威胁产量稳定与品质提升。大螟(Asian corn borer)作为玉米早期主要害虫之一,由于取食茎秆和破坏生长点及根系,常导致玉米幼苗枯心乃至死亡,对玉米产量与品质造成显著危害[3-4]。目前,大螟虫害的监测仍主要依赖人工观测幼苗心叶变化来判定危害程度,并结合经验预测其发生趋势。虽然该方法在玉米安全生产中具有一定参考价值,但其主观性强、空间代表性不足以及响应滞后[5],在高效和准确性上存在明显不足。对比之下,遥感技术可实现大螟的大面积且精准监测,对提高玉米品质具有重要意义[6-7]。

近年来,遥感技术凭借高时空分辨率、非破坏性和快速覆盖的优势,已成为农作物病虫害监测的重要技术途径[8-9]。YU 等[10]提出了基于高光谱与无人机多光谱数据融合的棉蚜虫植被指数,结合机器学习算法与智能优化算法实现虫害监测与 SPAD 反演,相关系数达 0.833,分类准确率达 93.1%,显著提高了虫害识别与生理参数的估测精度。周龙飞等[11]基于无人机 RGB 影像与机器学习方法,融合植被指数与纹理特征构建松材线虫病识别模型,SVM 模型在多特征融合下精度达 85.45%,较好地反映了病害空间分布特征。曹梦娇等[12]证实了无人机多光谱遥感结合双时相 SVM 能够有效评估早稻二化螟为害程度,预测结果与实地虫害分布高度一致。地力夏提·依马木等[13]基于无人机多光谱遥感影像的棉田虫害 Logistic 回归识别模型选取虫害敏感波段反射率及 SAVI、NDVI 等植被指数,构建棉蚜虫、棉红蜘蛛和棉铃虫多虫害识别模型,测试集精度达 0.905,基本满足棉田精准植保作业需求。总体来看,现有研究虽已充分证明无人机遥感结合机器学习在农作物病虫害识别中的有效性与应用潜力,但仍存在若干共性不足:大部分研究仍聚焦于单一感知数据源或少量传统植被指数,未能充分挖掘 RGB 影像中蕴含的纹理与颜色等细节信息,光谱、纹理和颜色等多源特征的协同表征与深度融合程度有限;大多数模型主要回答“是否受害”或开展相对粗略的危害等级划分,对虫害发生程度的精细分级有待提高。

针对上述不足,本研究以玉米幼苗期大螟虫害为研究对象,基于无人机获取 RGB 及多光谱遥感影像,系统提取多种植被指数、纹理特征和颜色指数,分别基于这些特征构建玉米大螟危害等级预测模型,以提高大螟危害等级监测精度,为玉米早期精准无损检测提供一种可靠方法,从而为有效防治大螟提供理论依据。

1 材料与方法

1.1 试验区概况

试验区位于山东省淄博市桓台县辕文村(37.01°N,118.03°E),其空间分布如图 1 所示。试验场地总长度 100 m,总宽度 35 m,种植密度为行距 60 cm、株距 25 cm,共设置 122 个试验区域。试验对象为夏玉米,于 2025 年 6 月 22 日播种,采用标准田间种植模式,包含灌溉、施肥和除草等常规田间管理措施。大螟是该试验地的主要虫害。

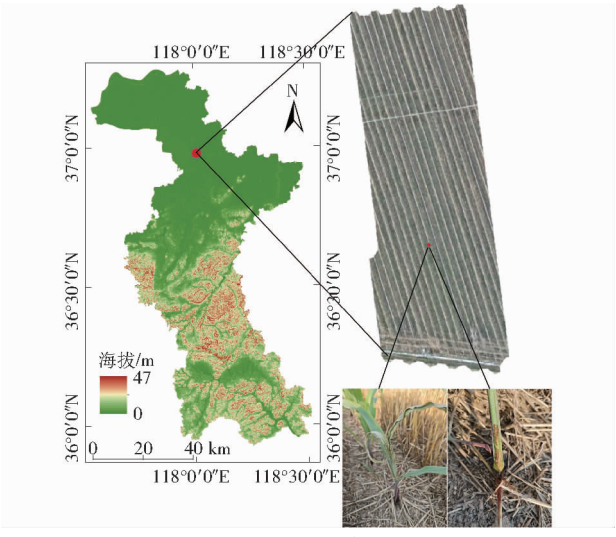

图 1 试验区位置图

Fig. 1 Location map of experimental area

1.2 无人机遥感影像采集与预处理

数据采集选择在晴朗无云、光照充足的天气条

件下进行，时间段为 10:00—14:00，以保证光照均匀。无人机平台采用 DJI Mavic 3M 型多光谱无人机（DJI），配备一台 2 000 万像素的 RGB 相机和 4 个 500 万像素的多光谱相机。多光谱相机包含绿、红、红边和近红外 4 个波段，其中心波长分别为 560、650、730、860 nm。飞行高度设为 20 m，图像采集的旁向重叠率为 70%，航向重叠率为 80%。在飞行前采集标准辐射校正板图像，并利用手持 RTK 采集试验小区的像控点坐标，用于后续的地理配准与校正。

影像获取后，使用 DJI Terra 对多光谱影像进行拼接处理，如图 2 所示。在 ENVI 5.6 软件中，采用马氏距离分类对玉米和土壤样本进行监督分类，即根据待分类样本与各已知类别之间的马氏距离，将样本划分至最近的类别[14]。分类结果以总体准确率（Overall accuracy）和 Kappa 系数（Kappa coefficient）进行评价，分别为 95.78% 和 0.898 6，并进一步二值化处理，将分类结果转化为 0 和 1 两个离散值，随后通过掩膜去除土壤背景，去除效果如图 3 所示，可见土壤背景已被有效分离，植被区域边缘清晰、纹理保持良好。经统计，土壤像素占比由去除前的约 92.83% 降至 7.17%，实现了较好的背景抑制效果。



图 2　原始遥感影像图

Fig. 2　Original remote sensing image

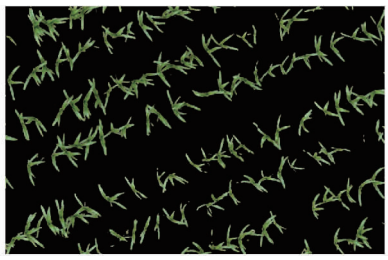

图 3　土壤去除效果图

Fig. 3　Soil removal effect map

1.3　大螟地面数据采集

在利用无人机获取 RGB 及多光谱影像的同时，通过人工监测的方法同步获取了 122 个小区的地面玉米大螟危害等级数据。由于尚无针对玉米大螟危害等级的统一评价标准，参考安徽省地方标准《水稻大螟测报调查规范》（DB 34/T 2904—2017），在试验田内采用平行跳跃式取样方法，每个小区随机连续选取 100 株玉米植株，记录其中的受害植株如枯心株、虫伤株和缺刻株等。按照螟害分级标准（表 1）计算每个试验小区的虫口密度，并根据虫口密度确定试验小区的危害等级（表 2）。虫口密度反映了害虫种群数量在空间上的密集程度，是衡量虫害发生轻重与种群动态变化的主要指标。虫口密度 d_i 计算公式为

$$d_i = \frac{M(L_i) - M_{\min}}{M_{\max} - M_{\min}} \tag{1}$$

式中　$M(L_i)$——大螟危害等级对应的原始虫口密度代表值，取值为平均虫口密度的中位数

$M_{\min}$——小区中虫口密度的最小代表值

$M_{\max}$——小区中虫口密度的最大代表值

表 1　大螟危害等级分类标准

Tab. 1　Corn borer damage level classification standard

螟害等级	划分标准	平均虫口密度范围/（头·百株$^{-1}$）	代表值/（头·百株$^{-1}$）
1 级（L1）	有蛀食玉米叶片现象，轻微缺刻	0 ~ 5	2.5
2 级（L2）	有蛀食玉米根部现象，且叶片有缺刻	5 ~ 10	7.5
3 级（L3）	玉米根部被啃食，且心叶有缩水现象	10 ~ 15	12.5
4 级（L4）	玉米根部被明显啃食，心叶枯黄	15 ~ 20	17.5
5 级（L5）	玉米根部被蛀食断裂，心叶及叶片枯黄	>20	20

表 2　试验小区大螟危害等级标准

Tab. 2　Grading standard of corn borer damage level in experimental plots

小区虫害等级	危害程度	虫口密度 d_i
1 级（L1）	轻发生	[0 ~ 0.286）
2 级（L2）	偏轻发生	[0.286 ~ 0.571）
3 级（L3）	中等发生	[0.571 ~ 0.857）
4 级（L4）	偏重发生	[0.857 ~ 1）
5 级（L5）	大发生	1

1.4　数据处理方法

1.4.1　植被指数计算

植被指数能够敏感地反映植被的生理与光谱特征变化，在作物病虫害监测领域发挥着关键作用。本文中，玉米早期光谱特征由可见光植被指数和多光谱植被指数构成，基于前人研究选用与玉米病虫害密切相关的 7 种可见光植被指数和 7 种多光谱植被指数[15-25]，如表 3 所示。

表 3 植被指数及其计算公式

Tab. 3 Vegetation indices and its calculation formula

植被指数类型	植被指数名称	计算公式
可见光植被指数	过量绿色指数(ExG)	$2G_v - R_v - B_v$
	过量红色指数(ExR)	$1.4R_v - G_v$
	绿色-红色差异指数(ExGR)	$2G_v - R_v - B_v - 1.4R_v - G_v$
	过量蓝色指数(ExB)	$1.4B_v - G_v$
	改进过量绿色指数(MExG)	$1.262G_v - 0.88R_v - 0.311B_v$
	植被提取颜色指数(CIVE)	$0.441R_v - 0.811G_v + 0.385B_v + 18.787\,45$
	绿红比指数(GRRI)	G_v/R_v
多光谱植被指数	归一化植被指数(NDVI)	$(N_m - R_m)/(N_m + R_m)$
	差异植被指数(DVI)	$N_m - R_m$
	土壤调节植被指数(SAVI)	$2.5\dfrac{N_m - R_m}{N_m + R_m + 0.5}$
	重归一化差异植被指数(RDVI)	$(N_m - R_m)/\sqrt{N_m + R_m}$
	优化土壤调节植被指数(OSAVI)	$(N_m - R_m)/(N_m + R_m + 0.16)$
	红边植被胁迫指数(RVSI)	$Re_m - \left[R_m + (N_m - R_m)\dfrac{Re_m - R_m}{N_m - R_m}\right]$
	改进叶绿素吸收比率指数(MCARI)	$[Re_m - R_m - 0.2(Re_m - G_m)]\dfrac{Re_m}{R_m}$

注:R_v、G_v、B_v分别代表 RGB 传感器的红、绿、蓝光谱反射率,R_m、N_m、G_m、Re_m分别代表多光谱传感器的红、近红外、绿和红边的光谱反射率。

1.4.2 纹理特征计算

为有效弥补植被指数仅反映光谱强度而忽略空间结构的不足,引入纹理特征变量。采用灰度共生矩阵(Gray-level co-occurrence matrix, GLCM)分析方法,深入探讨纹理特征与玉米大螟虫害之间的关系[26]。GLCM 能够将像素间的空间分布规律转化为可量化的矩阵,并进一步派生出描述纹理粗糙度、均匀性及规则性等特征的指标。在本研究中,基于多光谱图像的 4 个波段分别提取 8 类典型纹理特征,即均值(Mean, MEA)、方差(Variance, VAR)、同质性(Homogeneity, HOM)、相异性(Dissimilarity, DIS)、对比度(Contrast, CON)、熵(Entropy, ENT)、二阶矩(Second moment, SEM)和相关性(Correlation, COR)。在参数设置上,滑动窗口大小为 3×3,步长为 1。

1.4.3 颜色指数计算

将原始 RGB 色彩空间转换为 3 种替代性色彩空间模型:HSV、HLS 和 YCbCr[27]。其中,HSV 和 HLS 的转换通过 ENVI 5.6 软件中的“Color Transforms”工具实现,YCbCr 的转换计算公式为

$$Y = 0.229R + 0.587G + 0.114B \quad (2)$$

$$Cb = 0.568(B - Y) + 128 \quad (3)$$

$$Cr = 0.713(R - Y) + 128 \quad (4)$$

式中 Y——亮度分量

Cb——蓝色差分量

Cr——红色差分量

R——红色波段光谱反射率

G——绿色波段光谱反射率

B——蓝色波段光谱反射率

1.4.4 特征筛选方法

皮尔逊相关系数(Pearson correlation coefficient, PCC)是一种用于度量两个连续变量之间线性相关程度和方向的经典统计指标,其数值一般介于 -1 与 1 之间[28]。系数绝对值越接近 1,说明变量间线性关系越紧密;越接近 0,则相关性越弱。该方法在特征筛选与多元分析中应用广泛,可用于识别冗余或高度相关的自变量。利用 Origin 软件计算各植被指数、纹理特征与颜色指数之间的皮尔逊相关系数,对变量间相关性进行分析。

1.5 模型建立

将获取到的 122 组数据按照比例 7∶3 划分为训练集与测试集,并利用五折交叉验证来减少因数据集划分造成的模型精度误差。为了精准预测大螟危害等级,在 PyCharm 的 Python 编译器中,利用随机森林(RF)[29]、极端梯度提升算法(XGBoost)[30]、K 最近邻算法(KNN)[31]和类别提升算法(CatBoost)[32]4 种机器学习算法进行比较分析。

RF 和 KNN 均使用 Python 中的 scikit-learn(1.3.0)构建,XGBoost 和 CatBoost 分别使用 Python 中的 xgboost(1.7.6)和 catboost(1.2)构建。模型配置环境为:Intel i5 -11260H 2.60 GHz CPU、16 GB 内存、Nvidia GeForce RTX 3050 显卡、Windows 操作系统。

1.6 评价指标

为全面评估虫害等级预测模型的性能,选取总体准确率、精确率(Precision)、召回率(Recall)、F1

值和 Kappa 系数作为评价指标。总体准确率用于衡量整体分类的正确性；精确率表示被预测为某类的样本中实际属于该类的比例，反映模型减少误报的能力；召回率表示实际属于某类的样本中被正确识别的比例，体现模型降低漏报的能力；F1 值是精确率与召回率的调和平均值，能够综合反映模型在不同类别上的平衡表现；Kappa 系数则用于评价预测结果与真实分类之间的一致性，并剔除了随机一致性的影响，能够更客观地反映模型的整体分类效果。通过上述指标的综合分析，可以多维度评价模型在玉米大螟危害等级预测中的性能表现。

2　结果与讨论

2.1　基于植被指数模型分析

对 RGB 及多光谱构成的 14 种植被指数与玉米大螟危害等级进行相关性分析，结果如图 4 所示。相关性排名前六的指数依次为 ExG、SAVI、OSAVI、DVI、NDVI 和 ExGR，其相关系数 $|r|$ 分别为 0.88、0.87、0.81、0.74、0.73 和 0.61。值得注意的是，前 5 个指数与第 6 个指数之间的相关系数出现明显下降，表明第 6 名及之后的指数在信息贡献上急剧减弱，反而可能因噪声增加而加大模型学习难度，需要更多样本才能捕捉到微弱关系。因此，选取相关性最高的 5 个植被指数（ExG、SAVI、OSAVI、DVI、NDVI）作为自变量，构建 RF、XGBoost、KNN、CatBoost 4 类玉米大螟危害等级预测模型。

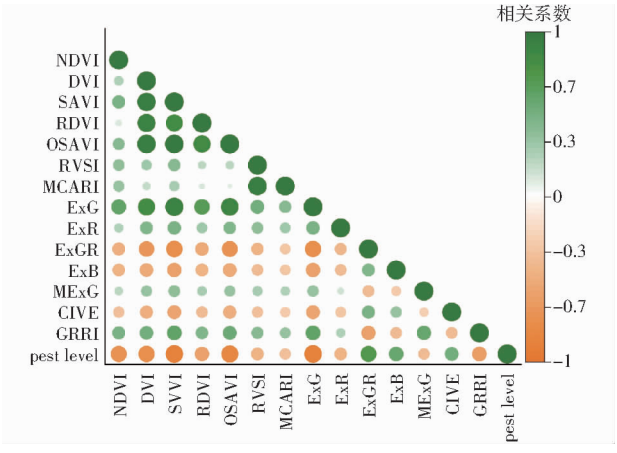

图 4　植被指数与大螟危害等级相关图

Fig. 4　Correlation between vegetation indices and corn borer damage levels

模型结果表明（表 4），KNN 在综合性能上表现最佳，其召回率、F1 值和 Kappa 系数分别达到 85.1%、85.7% 和 76.4%，均优于其他模型，显示出较强的整体预测能力。与 XGBoost、RF 和 CatBoost 相比，KNN 的召回率分别提升 9.7、4.7、2.4 个百分点，F1 值分别提升 6.8、6.7、6.1 个百分点，Kappa 系数分别提升 4.9、4.1、1.4 个百分点。与此同时，XGBoost 在精确率方面表现最佳，达到 86.5%，说明其在降低误报率方面具有优势。总体而言，植被指数能够有效提供虫害等级预测的信息，但单独依赖此类特征仍存在一定局限性，需结合其他特征以进一步提升模型的稳定性和适用性。

表 4　基于植被指数建模结果

Tab. 4　Modeling results based on vegetation indices

%

	模型	总体准确率	精确率	召回率	F1 值	Kappa 系数
训练集	RF	93.9	89.8	90.6	89.2	80.1
	XGBoost	94.2	94.2	83.1	86.6	77.8
	KNN	96.1	94.7	93.6	94.2	83.4
	CatBoost	90.7	90.9	89.5	86.4	80.2
测试集	RF	81.9	79.6	80.4	79.0	72.3
	XGBoost	85.2	86.5	75.4	78.9	71.5
	KNN	86.1	86.2	85.1	85.7	76.4
	CatBoost	82.7	84.1	82.7	79.6	75.0

2.2　基于纹理特征模型分析

基于多光谱 4 个波段提取 32 个纹理特征与玉米大螟危害等级进行相关性分析，结果如图 5 所示。相关性排名前十的纹理特征依次为：N－COR、N－SEC、N－ENT、Re－COR、N－VAR、N－DIS、N－MEA、Re－SEC、Re－MEA 和 Re－ENT，其相关系数 $|r|$ 分别为 0.98、0.92、0.82、0.82、0.81、0.80、0.80、0.80、0.80 和 0.80。可以发现，第 6 名至第 10 名特征的相关系数均为 0.80，信息量存在较高重叠性。为避免冗余特征引入过拟合风险，选取相关性最高的前 5 个纹理特征（N－COR、N－SEC、N－ENT、Re－COR、N－VAR）作为自变量，构建 RF、XGBoost、KNN、CatBoost 4 类玉米大螟危害等级预测模型。

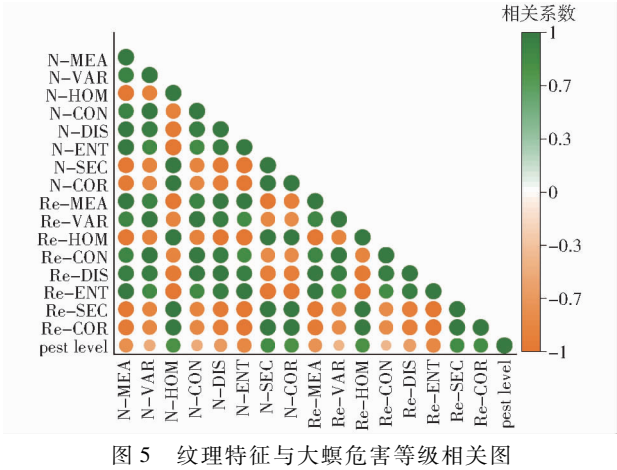

图 5　纹理特征与大螟危害等级相关图

Fig. 5　Correlation between texture features and corn borer damage levels

模型结果显示（表 5），KNN 在整体性能上表现

最佳，其总体准确率、精确率、召回率、F1 值和 Kappa 系数均达到最高值，分别为 73.7%、72.2%、73.7%、61.2% 和 57.4%。与 XGBoost、RF 和 CatBoost 相比，KNN 在召回率上分别提升 21.2、18.9、10.6 个百分点；在 F1 值上分别提升 0.8、10.8、4.2 个百分点；在 Kappa 系数上分别提升 6.2、1.6、9.1 个百分点。然而，与基于植被指数的预测模型相比，KNN 在纹理特征下的整体表现较差。总体而言，单一纹理特征对模型性能的提升有限，虽然能够提供一定的补充信息，但难以独立支撑高精度的大螟危害等级预测。

表 5 基于纹理特征建模结果

Tab.5 Modeling results based on texture features

%

	模型	总体准确率	精确率	召回率	F1 值	Kappa 系数
训练集	RF	80.1	63.8	61.6	57.2	61.0
	XGBoost	69.7	54.4	56.8	64.7	54.5
	KNN	79.7	77.3	78.8	66.3	61.3
	CatBoost	67.1	69.8	66.5	60.4	50.9
测试集	RF	72.1	57.0	54.8	50.4	55.8
	XGBoost	64.7	50.1	52.5	60.4	51.2
	KNN	73.7	72.2	73.7	61.2	57.4
	CatBoost	63.1	66.4	63.1	57.0	48.3

2.3 基于颜色指数模型分析

在颜色指数中，共计算了 HSV、HLS 和 YCbCr 3 种色彩空间指标。其中，HSV－H 与 HLS－H 中的 H(Hue)均反映 RGB 三通道的比例关系，而不涉及整体亮度的绝对值，因此二者在目标变量上的信息几乎完全一致。基于避免冗余的原则，最终选取了 HSV－H、HSV－S、HSV－V、HLS－L、HLS－S、YCbCr－Y、YCbCr－Cb、YCbCr－Cr 共 8 个特征进行相关性分析，结果如图 6 所示。分析发现，颜色指数整体与玉米大螟危害等级均呈显著相关性。为进一步提高模型的有效性并减少冗余，选取相关系数较高的 4 个颜色指数(HSV－H、HSV－S、YCbCr－Cb 和 HLS－S)作为自变量，相关系数|r|分别为 0.92、0.92、0.92 和 0.91，用于构建 RF、XGBoost、KNN 和 CatBoost 4 类玉米大螟危害等级预测模型。

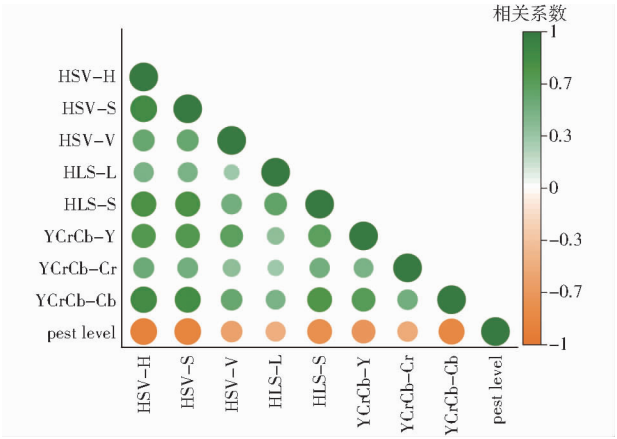

图 6 颜色特征与大螟危害等级相关性图

Fig.6 Correlation between color features and corn borer damage levels

结果表明(表 6)，基于颜色指数的预测模型中，KNN 表现最优，在总体准确率、精确率、召回率、F1 值和 Kappa 系数 5 个指标上均达到最大；CatBoost 次之，表现相对均衡。总体来看，颜色指数在玉米大螟危害等级预测中具有较强的直观性和一定的判别能力，但其易受环境因素干扰，且信息维度有限，因此更适合作为与植被指数、纹理特征等结合使用的重要补充信息。

表 6 基于颜色特征建模结果

Tab.6 Modeling results based on color features %

	模型	总体准确率	精确率	召回率	F1 值	Kappa 系数
训练集	RF	96.4	90.5	93.0	95.5	83.9
	XGBoost	91.7	94.1	89.6	91.4	82.5
	KNN	96.5	95.4	95.3	92.7	87.8
	CatBoost	90.2	90.6	98.1	88.0	81.5
测试集	RF	84.4	80.3	82.8	85.3	76.7
	XGBoost	82.7	86.4	81.9	83.7	76.6
	KNN	88.5	88.6	88.5	85.9	82.6
	CatBoost	85.2	86.3	84.8	83.7	78.2

2.4 基于植被指数和纹理特征融合模型分析

在单一特征分析的基础上，进一步将相关系数|r|最高的 5 种植被指数与 5 种纹理特征进行融合，分别选取植被指数 ExG、MExG、GRRI、ExB、CIVE，以及纹理特征 N－COR、N－SEC、N－ENT、Re－COR、N－VAR 作为输入变量，构建玉米大螟危害等级预测模型，结果如表 7 所示。植被指数与纹理特征融合后，KNN 模型整体表现最优，尤其在召回率和 Kappa 系数上表现出较强的泛化能力，分别达到

表 7 基于植被指数和纹理特征融合建模结果

Tab.7 Modeling results based on fusion of vegetation indices and texture features %

	模型	总体准确率	精确率	召回率	F1 值	Kappa 系数
训练集	RF	93.5	94.8	90.5	92.2	86.0
	XGBoost	91.7	92.2	79.8	84.0	79.0
	KNN	95.3	94.8	94.4	93.8	87.6
	CatBoost	90.8	91.3	90.2	87.2	83.3
测试集	RF	88.5	90.5	86.2	87.9	82.7
	XGBoost	87.7	88.8	76.4	80.6	76.4
	KNN	89.3	89.7	89.3	88.7	83.7
	CatBoost	86.8	87.9	86.8	83.8	80.7

89.3%、83.7%。而 RF 在精确率方面略优于 KNN。

与单一特征相比，融合特征能显著提升模型性能，KNN 在 F1 值和 Kappa 系数上较单一植被指数分别提升 3.0、7.3 个百分点，较单一纹理特征分别提升 27.5、26.3 个百分点，表明纹理特征在一定程度上弥补了植被指数信息不足的问题，从而增强了预测的稳定性与精度。

混淆矩阵结果如图 7 所示，进一步揭示了各模型在分类上的差异。RF 和 CatBoost 均有 5 处分类错误，XGBoost 有 6 处分类错误，而 KNN 为 4 处分类错误，表现出相对较低的误判率。但需要注意的是，KNN 在 L1 与 L2、L2 与 L3 以及 L3 与 L4 之间仍存在一定的混淆现象，从作物生理变化与特征响应规律来看，相邻危害等级间的混淆具有一定生物学合理性，L1、L2 阶段大螟主要取食个别植株或局部叶片，导致心叶轻微失水，叶绿素含量和冠层结构接近健康水平，使植被指数、光谱反射及纹理特征与轻度受害状态高度相似，易导致 L1 和 L2 间判别模糊。随危害由 L2 向 L3、L3 向 L4 递进，心叶萎蔫枯死比例逐步增加，但作物补偿生长和冠层退化是一个逐步累积的过程，而不是突然变化。由此导致冠层郁闭度、土壤背景暴露程度和冠层结构差异在特征空间中呈现连续过渡和缓慢变化，形成明显的“过渡带”，从而使 L2－L3、L3－L4 中低危害等级之间的特征更加重叠。相较之下，极低危害 L1 与极高危害 L5 在冠层完整性、色泽和背景暴露上的差异显著，光谱与纹理分布相对离散，因此模型在极端等级上的可分性更强、误分率更低。

2.5　基于植被指数和颜色指数融合模型分析

在相关系数|r|最高的特征中，融合了 5 种植被指数（ExG、MExG、GRRI、ExB 和 CIVE）与 4 种颜色指数（HSV－H、HSV－S、YCbCr－Cb 和 HLS－S）作为模型输入变量，构建玉米大螟危害等级预测模型（表 8）。植被指数与颜色指数融合后，RF 模型表现最佳，其 F1 值和召回率分别达到 90.4% 和 85.9%，较次优模型 KNN 分别提升 4.3、0.7 个百分点。

与单一特征相比，RF 模型在融合植被指数与颜色指数时，F1 值和召回率相较单一植被指数和颜色指数分别提升 11.4、5.5 个百分点和 5.1、3.1 个百分点。表明两类特征的互补性有效增强了模型的分类能力。然而，与植被指数和纹理特征融合的结果相比，KNN 和 RF 模型的总体准确率分别下降 4.1、4.9 个百分点，RF 的精确率下降了 5.9 个百分点，Kappa 系数也显著降低。这说明虽然植被指数与颜

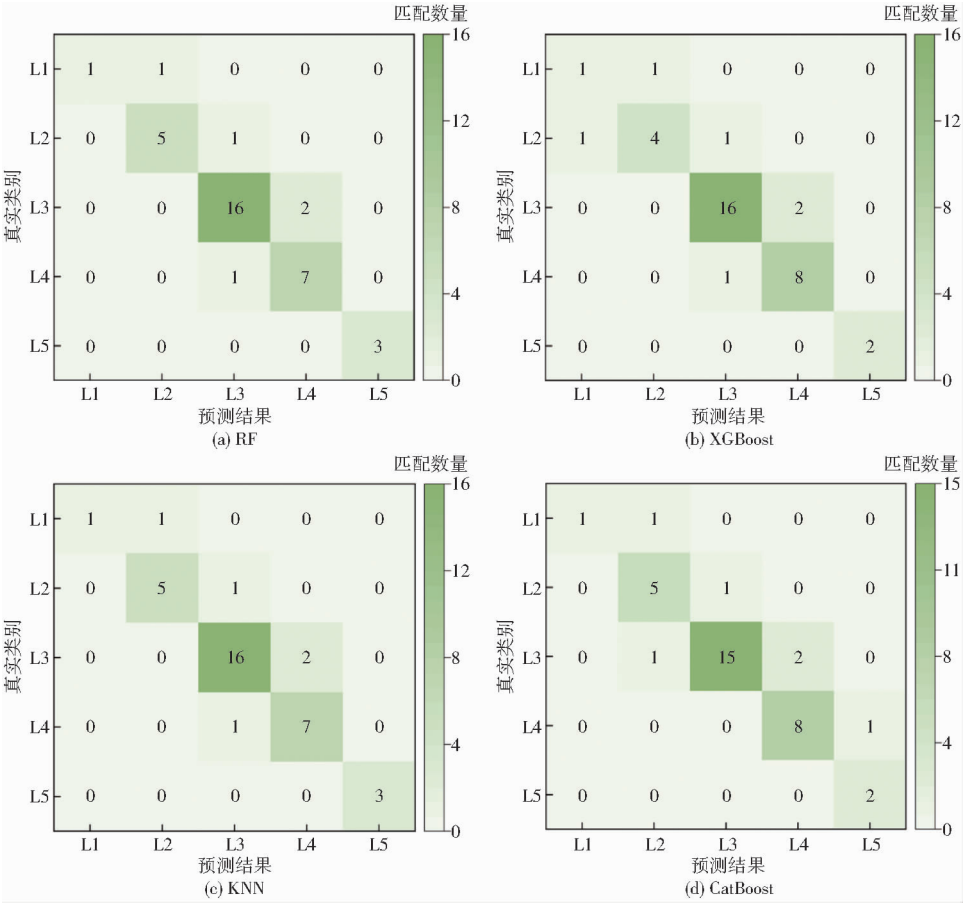

图 7　植被指数和纹理特征融合模型测试集混淆矩阵

Fig. 7　Vegetation index and texture feature fusion model test set confusion matrix

色指数的融合能够提升局部指标表现,但整体预测稳定性不足,泛化能力有待进一步提高。

表 8 基于植被指数和颜色特征融合建模结果

Tab.8 Modeling results based on fusion of vegetation indices and color features %

	模型	总体准确率	精确率	召回率	F1 值	Kappa 系数
训练集	RF	87.6	88.0	89.3	93.8	79.4
	XGBoost	87.3	86.0	77.7	81.6	74.5
	KNN	87.2	87.6	86.9	87.8	78.8
	CatBoost	82.3	83.8	82.0	88.0	73.0
测试集	RF	83.6	84.6	85.9	90.4	76.8
	XGBoost	84.3	83.4	75.1	79.0	72.5
	KNN	85.2	85.9	85.2	86.1	77.5
	CatBoost	80.3	82.1	80.3	86.3	71.7

2.6 基于纹理特征和颜色指数融合模型分析

在相关系数|r|最高的特征中,融合了 5 种纹理特征(N-COR、N-SEC、N-ENT、Re-COR 和 N-VAR)与 4 种颜色指数(HSV-H、HSV-S、YCbCr-Cb 和 HLS-S),构建玉米大螟危害等级预测模型,预测结果如表 9 所示。融合纹理特征与颜色指数后,XGBoost 模型表现最佳,在精确率和 F1 值上均达到最高,分别为 87.1% 和 85.5%;KNN 则在召回率和总体准确率上表现最优,分别为 86.0% 和 86.4%。

表 9 基于纹理特征和颜色指数融合建模结果

Tab.9 Modeling results based on fusion of texture features and color features %

	模型	总体准确率	精确率	召回率	F1 值	Kappa 系数
训练集	RF	87.7	84.1	85.5	77.3	80.3
	XGBoost	89.2	90.5	89.2	88.9	80.2
	KNN	89.4	89.1	88.6	84.1	80.5
	CatBoost	86.6	87.1	86.2	87.1	78.1
测试集	RF	85.7	82.4	83.8	75.6	79.0
	XGBoost	85.2	87.1	85.8	85.5	77.6
	KNN	86.4	86.5	86.0	81.5	78.5
	CatBoost	83.6	84.5	83.6	84.5	76.1

与单一特征相比,XGBoost 在纹理特征与颜色指数融合时,精确率和 F1 值分别较单一纹理特征与颜色指数分别提升 37.0、25.1 个百分点和 0.7、1.8 个百分点。KNN 在融合后较单一纹理特征在召回率和总体准确率上分别提升 12.3、12.7 个百分点,但较单一颜色指数则分别下降 2.5、2.1 个百分点。进一步对比不同融合方式,XGBoost 在纹理特征和颜色指数融合下的精确率和总体准确率较植被指数和纹理特征融合分别下降 1.7、2.5 个百分点,但较植被指数和颜色指数融合则提升 3.7、0.9 个百分点;而 KNN 在纹理特征和颜色指数融合下的召回率和总体准确率较植被指数和纹理特征融合分别降低 3.3、2.9 个百分点,但较植被指数和颜色指数融合则分别提升 0.8、1.2 个百分点。

总体来看,纹理特征与颜色指数融合能够在一定程度上提升模型局部指标的表现,但整体预测效果仍不及植被指数与纹理特征或植被指数与颜色指数的融合,说明纹理特征和颜色指数融合对玉米大螟危害等级的判别能力有限。

2.7 基于植被指数、纹理特征和颜色指数融合模型分析

在单特征与双特征组合分析的基础上,进一步融合了相关系数|r|最高的 5 种植被指数(ExG、MExG、GRRI、ExB 和 CIVE)、5 种纹理特征(N-COR、N-SEC、N-ENT、Re-COR 和 N-VAR)以及 4 种颜色指数(HSV-H、HSV-S、YCbCr-Cb 和 HLS-S),构建玉米大螟危害等级预测模型,结果如表 10 所示,3 类特征融合后,KNN 模型在各项指标上均表现最优,预测结果稳定且具有良好的泛化性。与最佳双特征输入模型 KNN 融合植被指数和纹理特征模型相比,KNN 在总体准确率、精确率、召回率、F1 值和 Kappa 系数上分别提升 2.5、2.2、2.5、0.8、3.7 个百分点,进一步验证了其在大螟危害等级预测中的稳定性与优势。

表 10 基于植被指数、纹理特征和颜色指数建模结果

Tab.10 Modeling results based on fusion of vegetation indices, texture features and color features %

	模型	总体准确率	精确率	召回率	F1 值	Kappa 系数
训练集	RF	89.2	86.8	87.2	87.0	80.5
	XGBoost	89.1	90.3	78.5	82.4	79.0
	KNN	96.8	96.2	96.1	93.8	90.7
	CatBoost	85.7	87.3	85.3	89.5	77.0
测试集	RF	85.2	83.4	83.8	83.6	77.9
	XGBoost	85.2	86.9	75.1	79.0	76.4
	KNN	91.8	91.9	91.8	89.5	87.4
	CatBoost	82.7	84.7	82.7	86.9	75.0

为更直观地比较不同模型对玉米大螟危害等级的识别效果,绘制了以 3 类特征为输入的混淆矩阵,如图 8 所示。结果表明,RF 和 XGBoost 模型均存在 7 处错误分类,CatBoost 的错误分类数为 8 处,而 KNN 错误分类数最少,仅为 3 处。与双特征输入植被指数和纹理特征的 KNN 模型相比,三特征输入下仅 KNN 的错误分类数减少了 1 处,而 RF、XGBoost 和 CatBoost 的错误分类数则均增加 2 处。

综上所述,玉米幼苗在受大螟危害后通常表现

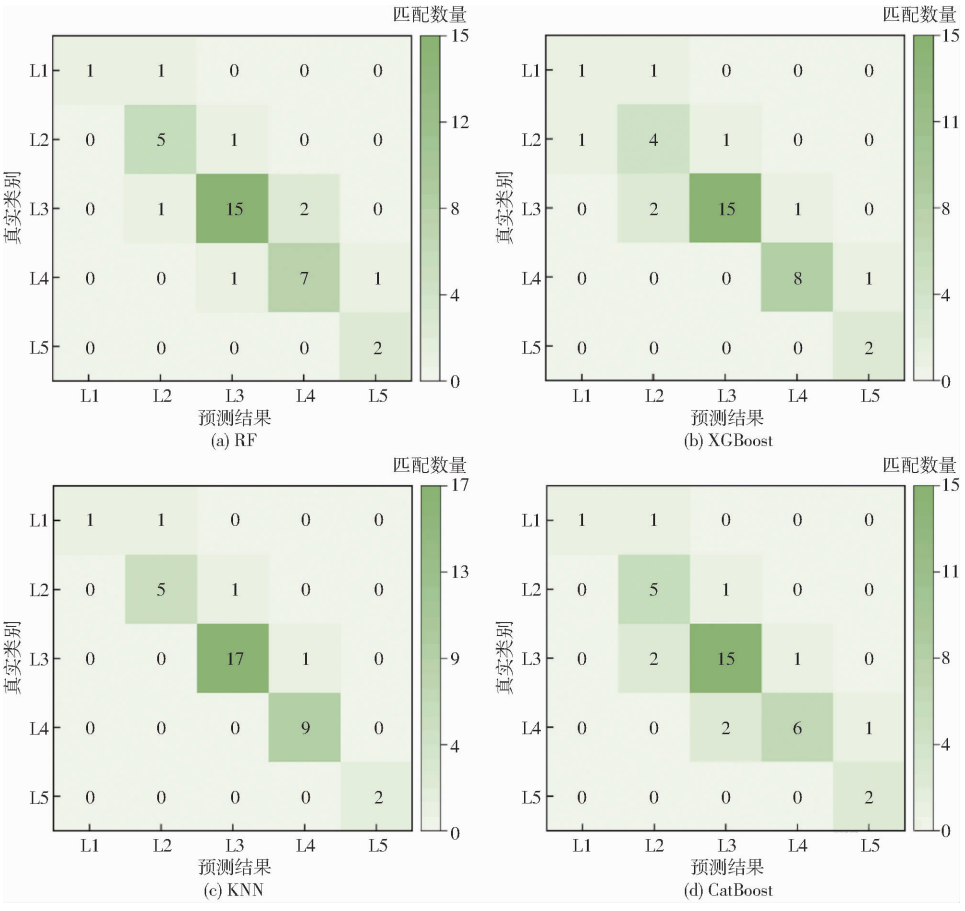

图 8　植被指数、纹理特征和颜色指数融合模型测试集混淆矩阵

Fig. 8　Vegetation index, texture feature and color index fusion model test set confusion matrix

为心叶表面失水萎缩、黄化和褪绿等典型症状，融合植被指数、纹理特征和颜色指数的 KNN 模型能够有效捕捉这些表型变化，可显著提升玉米早期大螟危害等级预测精度，从而为玉米早期病虫害的监测与防控提供可靠的技术支撑。

2.8　空间分布图

将大螟危害的空间可视化图用于将抽象的数值结果转化为直观的图像形式。以植被指数（ExG、MExG、GRRI、ExB 和 CIVE）、纹理特征（N－COR、N－SEC、N－ENT、Re－COR 和 N－VAR）和颜色指数（HSV－H、HSV－S、YCbCr－Cb 和 HLS－S）的遥感影像作为最佳输入特征组合，利用 Python 中的 scikit-image（0.24.0）包构建数据处理模型。如图 9 所示，该可视化结果能够直观反映虫害在不同区域的分布规律，作为模型预测结果的重要空间对照手段，可有效评估防治措施的实际效果，并为农业管理由传统经验驱动向数据驱动的智能决策转变提供技术支撑。

将不同特征及其组合输入至多种模型，系统评估了各类特征及其融合在不同模型中的预测表现。结果显示，当单一特征作为输入时，KNN 模型整体性能最优，其中颜色指数的总体准确率、精确率、召

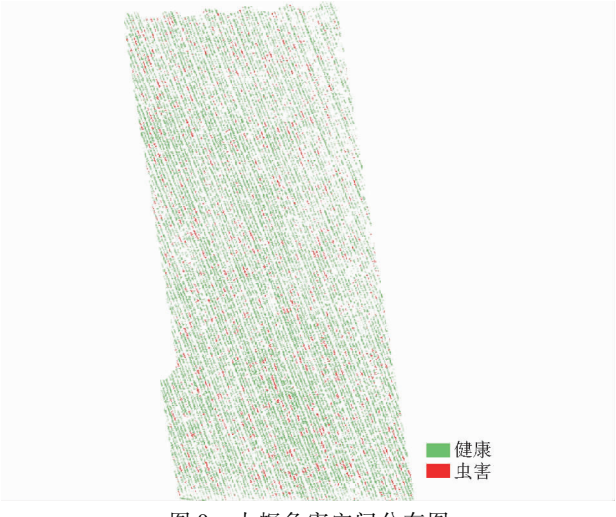

图 9　大螟危害空间分布图

Fig. 9　Spatial distribution map of corn borer infestation

回率、F1 值和 Kappa 系数分别达到 88.5%、88.6%、88.5%、85.9% 和 82.6%。以纹理特征为输入时，KNN 模型在上述 5 项指标上较颜色指数模型分别下降 14.8、16.4、14.8、24.7、25.2 个百分点，但 KNN 性能仍高于其他模型。总体而言，KNN 在单一特征输入条件下表现出优越的预测能力。

当输入双特征时，KNN、RF 和 XGBoost 模型输入特征分为“植被指数＋纹理特征”、“植被指数＋

颜色指数”和“纹理特征 + 颜色指数”3 类组合。其中,KNN 在“植被指数 + 纹理特征”融合下的性能优于其他模型在任意特征组合下的表现。总体而言,双特征输入的模型性能均明显优于单特征输入,表明不同特征之间的互补性能够有效提升模型的预测精度,尤其是在植被指数与纹理特征融合时对大螟危害等级的预测效果最为显著。这表明,单独的植被指数仅能反映光谱变化,缺乏空间结构信息,难以区分受害程度相近的样本;而引入纹理特征后,有效补充了冠层形态与空间分布差异的信息,从而提升了模型对大螟危害等级的识别精度与稳定性。该结果与廖娟等[33]在棉蚜虫危害等级监测中的结论相一致,均表明将光谱信息与纹理特征相融合可有效弥补单独使用光谱信息在高冠层覆盖度或局部遮挡条件下识别精度下降的不足,从而验证了光谱与空间信息融合在植被虫害监测中的有效性。

当 3 种特征共同输入模型时,KNN 依然表现出最优性能,其 5 项评价指标均高于 RF、XGBoost 和 CatBoost 模型。而 RF、XGBoost、CatBoost 在三特征融合时的总体性能较双特征输入略有下降,仅 KNN 在三特征融合下表现出持续提升。从模型特性与特征适配性角度分析,KNN 属于基于距离度量的惰性学习算法,在样本规模有限且植被指数、纹理特征和颜色指数之间具有较强互补性的情况下,引入更多维度有助于在多特征空间中拉大不同危害等级样本的邻域距离,从而提高局部相似性判别能力,因此三特征融合能够显著增强其对大螟危害等级的预测精度与稳定性。相反 RF、XGBoost 和 CatBoost 均以决策树为基础学习器构建集成模型,其中 XGBoost 和 CatBoost 采用梯度提升框架,对高维、小样本且特征相关性较强的数据更敏感,3 类特征叠加后冗余和噪声维度增加,易导致划分碎片化和一定程度的过拟合,使其在测试集上的总体性能较双特征输入略有回落。进一步证明,植被指数、纹理特征与颜色指数的融合在 KNN 模型中能够显著增强模型对大螟危害等级的预测精度与稳定性。

3 结论

(1)利用无人机 RGB 与多光谱遥感影像数据可以有效监测玉米大螟危害程度,通过不同的特征组合形式可以有效提高玉米大螟危害等级模型的精度。

(2)采用马氏距离分类算法将玉米与土壤分类并进行二值化掩膜剔除土壤背景,分别提取了 14 种植被指数、32 种纹理特征和 8 种颜色指数,采用皮尔逊相关系数进行特征选择,选择了 5 种植被指数、5 种纹理特征和 4 种颜色指数。基于植被指数(ExG、MExG、GRRI、ExB 和 CIVE)的 KNN 模型总体准确率、精确率、召回率、F1 值和 Kappa 系数分别为 86.1%、86.2%、85.1%、85.7% 和 76.4%,表明当玉米受大螟侵扰后,叶片会出现黄化、枯萎和脱水等现象,导致光谱反射特征发生变化,植被指数能在一定程度上反映这种生理退化过程。基于 RGB 波段构建颜色指数(HSV - H、HSV - S、YCbCr - Cb 和 HLS - S)的 5 类评价指标分别为 88.5%、88.6%、88.5%、85.9% 和 82.6%,能够敏感地反映病虫害导致的叶片颜色变化,较早地捕捉病变信息,有助于早期诊断与预警。基于纹理特征(N - COR、N - SEC、N - ENT、Re - COR 和 N - VAR)的 KNN 模型 5 类评价指标分别为 73.7%、72.2%、73.7%、61.2% 和 57.4%,均低于植被指数和颜色指数对模型产生的影响,这表明纹理特征对玉米大螟早期虫害的敏感度较弱,导致模型的总体精度较低。

(3)将植被指数、纹理特征和颜色指数融合构建的 KNN 模型表现最佳,其总体准确率、精确率、召回率、F1 值和 Kappa 系数分别达到 91.8%、91.9%、91.8%、89.5% 和 87.4%。相较于使用最佳单特征(颜色指数),5 项指标分别提升了 3.3、3.3、3.3、3.6、4.8 个百分点;相较于最佳双特征组合(植被指数与纹理特征融合),5 项指标分别提升了 2.5、2.2、2.5、0.8、3.7 个百分点。这表明,植被指数能够反映虫害对植株生理状态的光谱响应,纹理特征补充了冠层的结构与空间分布信息,而颜色指数揭示了叶片的视觉症状。3 类特征相互补充,从“光谱-结构-色彩”3 个维度全面刻画了大螟危害特征,从而显著提升了模型的预测精度与稳定性。另外,以植被指数、纹理特征和颜色指数为依据,构建大螟危害空间分布图,为精准防控、效果评估及智慧农业决策提供了科学依据。

参 考 文 献

[1] 王振营, 王晓鸣. 我国玉米病虫害发生现状、趋势与防控对策[J]. 植物保护, 2019,45(1):1 - 11.
WANG Zhenying, WANG Xiaoming. Current status and management strategies for corn pests and diseases in China[J]. Plant Protection,2019, 45(1): 1 - 11. (in Chinese)

[2] 张凝, 杨贵军, 赵春江, 等. 作物病虫害高光谱遥感进展与展望[J]. 遥感学报, 2021,25(1):403 - 422.
ZHANG Ning, YANG Guijun, ZHAO Chunjiang, et al. Progress and prospects of hyperspectral remote sensing technology for crop diseases and pests[J]. Journal of Remote Sensing, 2021, 25(1): 403 - 422. (in Chinese)

[3] 李传艳，于晓锐，唐良德，等. 大螟的研究进展：系统综述[J/OL]. 环境昆虫学报. http://link.cnki.net/urlid/44.1640.Q.20250407.0948.002.
LI Chuanyan, YU Xiaorui, TANG Liangde, et al. Research progress on *Sesamia inferens* (Lepidoptera: Noctuidae): a systematic review[J/OL]. Journal of Environmental Entomology. http://link.cnki.net/urlid/44.1640.Q.20250407.0948.002. (in Chinese)

[4] STOUT M J, MCCARTER K, VILLEGAS J M, et al. Natural incidence of stem borer damage in U.S. rice varieties[J]. Crop Protection, 2024, 177: 106565.

[5] 罗志明，尹炯，黄应昆，等. 高原蔗区甘蔗螟虫种群结构及螟害枯心苗发生规律[J]. 应用昆虫学报，2017，54(5)：838－844.
LUO Zhiming, YIN Jiong, HUANG Yingkun, et al. Community structure of the sugarcane borer and the frequency of occurrence of borer-damaged dead sugarcane hearts during the seedling stage in paddy, and upland, sugar cane fields[J]. Chinese Journal of Applied Entomology, 2017, 54(5): 838－844. (in Chinese)

[6] 宋勇，陈兵，王琼，等. 无人机遥感监测作物病虫害研究进展[J]. 棉花学报，2021，33(3)：291－306.
SONG Yong, CHEN Bing, WANG Qiong, et al. Research advances of crop diseases and insect pests monitoring by unmanned aerial vehicleremote sensing[J]. Cotton Science, 2021, 33(3): 291－306. (in Chinese)

[7] 熊炜，王红波，张凯，等. 我国重大病虫害防控综合技术研发与示范专项顶层布局及实施进展[J]. 植物保护学报，2024，51(4)：741－751.
XIONG Wei, WANG Hongbo, ZHANG Kai, et al. Top design and progress in comprehensive technology research, development, and demonstration for the prevention and control of major pests and diseases in China[J]. Journal of Plant Protection, 2024, 51(4): 741－751. (in Chinese)

[8] 陆宴辉，陈捷胤，刘杰，等. 新时期我国农作物病虫害绿色防控策略研究[J]. 植物保护，2025，51(5)：35－44.
LU Yanhui, CHEN Jieyin, LIU Jie, et al. Research on the present strategy of green management of crop pests in China[J]. Plant Protection, 2025, 51(5): 35－44. (in Chinese)

[9] 马春森，林清彩，赵飞. 全球气候变化对作物病虫害的影响[J]. 植物保护，2025，51(5)：55－73.
MA Chunsen, LIN Qingcai, ZHAO Fei. Impacts of global climate change on crop pests and diseases[J]. Plant Protection, 2025, 51(5): 55－73. (in Chinese)

[10] YU H, HU L, CUI W, et al. A novel vegetation index for monitoring the stress levels of pest caused by dusky cotton bug[J]. Computers and Electronics in Agriculture, 2025, 234: 110221.

[11] 周龙飞，金诗怡，徐小文，等. 基于无人机遥感和机器学习的松材线虫病监测研究[J]. 遥感技术与应用，2025，40(3)：520－531.
ZHOU Longfei, JIN Shiyi, XU Xiaowen, et al. Monitoring of pine wilt disease based on UAV remote sensing and machine learning[J]. Remote Sensing Technology and Application, 2025, 40(3): 520－531. (in Chinese)

[12] 曹梦娇，白石，唐攀攀，等. 基于无人机多光谱遥感的早稻二化螟为害程度评价[J]. 浙江农业学报，2025，37(3)：603－611.
CAO Mengjiao, BAI Shi, TANG Panpan, et al. Evaluation of damage degree of Chilo suppressalis on early rice based on unmanned aerial vehicle multispectral remote sensing[J]. Acta Agriculturae Zhejiangensis, 2025, 37(3): 603－611. (in Chinese)

[13] 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 imagery[J]. Journal of South China Agricultural University, 2022, 43(2): 87－95. (in Chinese)

[14] 张兵. 高光谱图像处理与信息提取前沿[J]. 遥感学报，2016，20(5)：1062－1090.
ZHANG Bing. Advancement of hyperspectral image processing and information extraction[J]. Journal of Remote Sensing, 2016, 20(5): 1062－1090. (in Chinese)

[15] 祝清震，朱艳秋，王爱臣，等. 基于无人机多光谱植被指数与纹理特征的水稻叶绿素含量反演[J]. 农业机械学报，2024，55(12)：287－293.
ZHU Qingzhen, ZHU Yanqiu, WANG Aichen, et al. Accurate inversion of rice chlorophyll content by integrating multispectral and texture features derived from UAV multispectral imagery[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 287－293. (in Chinese)

[16] 邵明超，安敬威，刘博睿，等. 基于多模态数据的小麦苗情综合评估研究[J]. 中国农业科学，2025，58(19)：3857－3871.
SHAO Mingchao, AN Jingwei, LIU Borui, et al. Comprehensive assessment of wheat seedling growth status based on multimodal data[J]. Scientia Agricultura Sinica, 2025, 58(19): 3857－3871. (in Chinese)

[17] 翟长远，刘博浩，李翠玲，等. 葡萄主要病害检测与分级方法研究进展[J]. 农业机械学报，2025，56(8)：341－359.
ZHAI Changyuan, LIU Bohao, LI Cuiling, et al. Research progress of detection and grading methods for major grapevine diseases[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(8): 341－359. (in Chinese)

[18] 马元花，汪乐印，张祯鑫，等. 融合光谱和纹理特征的玉米产量预测研究[J]. 西北农业学报，2024，33(10)：1827－1838.
MA Yuanhua, WANG Leyin, ZHANG Zhenxin, et al. Remote sensing estimation for maize yield integrating spectral and texture features[J]. Acta Agriculturae Boreali-Occidentalis Sinica, 2024, 33(10): 1827－1838. (in Chinese)

[19] 冯美臣，苏悦，林涛，等. 基于无人机多源遥感数据和机器学习的高通量棉花估产研究[J]. 农业机械学报，2025，

56(3):169 – 179.
FENG Meichen, SU Yue, LIN Tao, et al. High throughput cotton yield estimation based on multi-source remote sensing data from unmanned aerial vehicles and machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 169 – 179. (in Chinese)

[20] 朱文静, 戴世元, 冯展康, 等. 基于垄间背景剔除优化小麦赤霉病遥感监测精度[J]. 农业工程学报, 2024, 40(7): 219 – 229.
ZHU Wenjing, DAI Shiyuan, FENG Zhankang, et al. Optimizing wheat scab in remote sensing monitoring accuracy using interridge background elimination[J]. Transactions of the CSAE, 2024, 40(7): 219 – 229. (in Chinese)

[21] 陈盛德, 陈一钢, 徐小杰, 等. 基于无人机多光谱遥感的玉米 LAI 监测研究[J]. 华南农业大学学报, 2024, 45(4): 608 – 617.
CHEN Shengde, CHEN Yigang, XU Xiaojie, et al. Monitoring of corn leaf area index based on multispectral remote sensing of UAV[J]. Journal of South China Agricultural University, 2024, 45(4): 608 – 617. (in Chinese)

[22] 高丽, 于灵雪, 包伦, 等. 基于无人机多光谱遥感的草甸草原地上生物量反演[J/OL]. 生态学杂志. http://link.cnki.net/urlid/21.1148.Q.20251014.1121.006.
GAO Li, YU Lingxue, BAO Lun, et al. Estimation of aboveground biomass in meadow steppes based on unmanned aerial vehicle hyperspectral remote sensing[J/OL]. Chinese Journal of Ecology. http://link.cnki.net/urlid/21.1148.Q.20251014.1121.006. (in Chinese)

[23] 王文辉, 田超, 鲁圣权, 等. 基于无人机多光谱影像和冠层形态的冬小麦叶绿素含量监测研究[J/OL]. 麦类作物学报. http://link.cnki.net/urlid/61.1359.S.20250929.0951.002.
WANG Wenhui, TIAN Chao, LU Shengquan, et al. Monitoring leaf chlorophyll content of winter wheat based on multispectral imagery and canopy morphology derived from unmanned aerial vehicles[J/OL]. Journal of Triticeae Crops. http://link.cnki.net/urlid/61.1359.S.20250929.0951.002. (in Chinese)

[24] 史胜炜, 柯祥麒, 刘伟伟. 水稻细条病对叶片反射率和日光诱导叶绿素荧光的影响[J]. 福建农林大学学报(自然科学版), 2024, 53(6):721 – 731.
SHI Shengwei, KE Xiangqi, LIU Weiwei. Effect of rice bacterial leaf streak on leaf reflectance and solar-induced chlorophyll fluorescence[J]. Journal of Fujian Agriculture and Forestry University(Natural Science Edition), 2024, 53(6): 721 – 731. (in Chinese)

[25] 谷晓博, 徐洋, 程智楷, 等. 基于无人机多光谱遥感的覆膜冬小麦叶片含水率反演[J]. 农业机械学报, 2025, 56(9): 547 – 556.
GU Xiaobo, XU Yang, CHENG Zhikai, et al. Inversion of leaf water content for mulched winter wheat based on multi-spectral remote sensing of unmanned aerial vehicle[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(9): 547 – 556. (in Chinese)

[26] 张磊, 宫兆宁, 王启为, 等. Sentinel – 2 影像多特征优选的黄河三角洲湿地信息提取[J]. 遥感学报, 2019, 23(2): 313 – 326.
ZHANG Lei, GONG Zhaoning, WANG Qiwei, et al. Wetland mapping of Yellow River Delta wetlands based on multi-feature optimization of Sentinel – 2 images[J]. Journal of Remote Sensing, 2019, 23(2): 313 – 326. (in Chinese)

[27] 张建华, 孔繁涛, 吴建寨, 等. 基于改进 VGG 卷积神经网络的棉花病害识别模型[J]. 中国农业大学学报, 2018, 23(11):161 – 171.
ZHANG Jianhua, KONG Fantao, WU Jianzhai, et al. Cotton disease indentification model based on improved VGG convolution neural network[J]. Journal of China Agricultural University, 2018, 23(11): 161 – 171. (in Chinese)

[28] 王平. 基于改进 Boruta 算法的森林地上生物量遥感估测研究[D]. 长沙:中南林业科技大学, 2022.
WANG Ping. Research on remote sensing estimation of forest aboveground biomass based on improved Brouta algorithm[D]. Changsha: Central South University of Forestry and Technology, 2022. (in Chinese)

[29] PUTRA A N, PRASETYA N R, HERMAWAN N, et al. Integrating remote sensing and random forest for accurate prediction of soil and biomass phosphorus dynamics in rice fields across complex terrain[J]. Soil Security, 2025, 21:100204.

[30] QIN N, ZHOU X, WANG K, et al. Forecasting the mechanical compaction influence on soybean yield using XGBoost – ANN[J/OL]. Information Processing in Agriculture. http://doi.org/10.1016/j.inpa.2025.09.002.

[31] SCHLEICH A, VEGA C, RENAUD J, et al. kNN-Bagging NFI, GEDI, Sentinel – 2 and Sentinel – 1 data to produce estimates of forest volumes[J]. Forest Ecology and Management, 2025, 595:122964.

[32] RAHIMI M, KARBASI M, JAMEI M, et al. Meticulous estimation of maize actual evapotranspiration: a comprehensive explainable CatBoost algorithm reinforced with Jackknife uncertainty paradigm[J]. Computers and Electronics in Agriculture, 2025, 237:110599.

[33] 廖娟, 王辉, 梁业雄, 等. 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[J]. 农业机械学报, 2025, 56(5):91 – 102.
LIAO Juan, WANG Hui, LIANG Yexiong, et al. UAV monitoring of cotton aphid damage levels based on fusion of spectral bands, texture features and vegetation indices[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(5):91 – 102. (in Chinese)