doi:10.6041/j.issn.1000-1298.2023.03.024

病害胁迫下玉米 LAI 遥感反演研究

刘帅兵[1]　金秀良[2,3]　冯海宽[4]　聂臣巍[2,3]　白　怡[2]　程明瀚[2]

(1. 武汉大学遥感信息工程学院, 武汉 430079; 2. 中国农业科学院作物科学研究所, 北京 100081;
3. 中国农业科学院国家南繁研究院, 三亚 572024; 4. 北京市农林科学院信息技术研究中心, 北京 100097)

摘要: 为了在病害发生条件下进行玉米 LAI 的遥感估算,针对 41 个不同抗性的玉米自交系品种,通过人工接种方法,获得了不同病害严重程度(1~9 级)的 LAI 数据,同时采集了地面高光谱和无人机多光谱数据,构建了 K 近邻算法、支持向量机、梯度提升分类树和决策分类树分类模型对病害进行分类,对玉米种质资源抗病性进行了划分。基于不同玉米病害胁迫程度分类结果,采用随机森林回归、梯度提升回归树、极端梯度增强算法、轻量梯度提升机 4 种机器学习模型对玉米 LAI 进行反演,讨论了不同模型在病害胁迫下的鲁棒性。研究结果表明,对不同生育期玉米病害程度进行划分,基于地面高光谱识别精度分别为 84.72%(梯度提升分类树)、47.67%(支持向量机)、55.05%(K 近邻算法)、83.02%(决策分类树)。基于病害分类结果,本文利用无人机多光谱数据估算了不同病情等级胁迫下的玉米 LAI 。构建了 4 种集成学习模型对不同病情等级的 LAI 进行估算,4 个 LAI 反演模型的总体反演精度(rRMSE)分别为: 19.11%(梯度提升回归树)、15.94%(轻量梯度提升机)、14.51%(随机森林回归)和 15.45%(极端梯度增强算法)。其中极端梯度增强算法对病害胁迫的普适性最好,不同病害等级下的反演精度 rRMSE 为 15.19%(轻微)、17.46%(中等)、9.12%(严重)和 9.63%(不抗病)。LAI 反演模型普遍在病害早期和中期(病情等级 1~7)对玉米 LAI 估算精度相差不大。但是对病情极其严重的玉米样本,其玉米 LAI 估算结果精度差异较大,田间不同病情等级胁迫会影响玉米 LAI 的准确估算。

关键词: 玉米病害; 叶面积指数; 无人机; 高光谱; 多光谱

中图分类号: TP75　　**文献标识码**: A　　**文章编号**: 1000-1298(2023)03-0246-13　　**OSID**:

Analysis of Effect of Disease Stress on Maize LAI Remote Sensing Estimation

LIU Shuaibing[1]　JIN Xiuliang[2,3]　FENG Haikuan[4]　NIE Chenwei[2,3]　BAI Yi[2]　CHENG Minghan[2]

(1. *School of Remote Sensing and Information Engineering*, *Wuhan University*, *Wuhan* 430079, *China*
2. *Institute of Crop Science*, *Chinese Academy of Agricultural Sciences*, *Beijing* 100081, *China*
3. *National Nanfan Research Institute (Sanya)*, *Chinese Academy of Agricultural Sciences*, *Sanya* 572024, *China*
4. *Information Technology Research Center*, *Beijing Academy of Agriculture and Forest Sciences*, *Beijing* 100097, *China*)

Abstract: Leaf area index (LAI) is a significant phenotypic parameter to characterize maize growth information. Accurate estimation of LAI under disease stress using UAV with multispectral camera is important for phenotypic research and breeding engineering. Maize disease is a common problem in the process of germplasm resources identification and breeding. The remote sensing estimation of maize LAI under the condition of disease occurrence needs to be considered. Firstly, the LAI data of different disease severities (grade 1 ~ 9) were obtained from 41 maize inbred lines with different disease resistances by artificial inoculation. The leaf-scale ASD FieldSpec PRO 4 hyperspectral data of maize were collected to classify the disease resistance of different maize germplasm resources. The hyperspectral indexes related to leaf nitrogen, chlorophyll and specific leaf weight were constructed, and the recognition models of different maize disease grades were developed. To identify different maize disease grades, the hyperspectral indexes relating to leaf nitrogen, chlorophyll, and specific leaf weight were developed and used in the recognition models. Four integrated learning models, K-nearest neighbours (KNN), support vector machine (SVM), gradient boosting decision tree (GBDT) and decision tree (DT) were

收稿日期: 2022-11-18　修回日期: 2023-01-03

基金项目: 国家重点研发计划项目(2016YFD0300602)、国家自然科学基金项目(42071426、51922072、51779161、51009101)、海南省崖州湾种子实验室项目(JBGS+B21HJ0221)和中国农业科学院南繁研究院南繁专项(YJTCY01、YBXM01)

作者简介: 刘帅兵(1994—),男,研究实习员,博士,主要从事农业定量遥感、作物表型与深度学习研究,E-mail: liushuaibing@whu.edu.cn

constructed to classify the disease resistance of different maize germplasm resources. Multi-spectral images were obtained from the Rededge－MX5 multispectral camera carried on DJI Matrice M600 Pro (UAV) at different stages of maize growth. Based on red edge and near infrared bands, a variety of vegetation indices were constructed to estimate the maize LAI. According to maize disease recognition model, different disease stress levels were classified and identified. The robustness of LAI estimation model under different disease stress was discussed by using the four integrated machine learning models of random forest regression (RFR), extreme gradient boosting (XGBoost), light gradient boosting machine (LightGBM), and GBDT. The results showed that based on the ground ASD hyperspectral recognition accuracy of OA: 84.72% (GBDT), 47.67% (SVM), 55.05% (KNN) and 83.02% (DT), respectively, according to the classification of maize disease degree in different growth stages. The early stages of maize infection were difficult to distinguish from healthy leaves due to the mild symptoms of the disease. As the severity of maize disease was increased, the difference between healthy leaves and diseased spots in images was gradually increased, resulting in higher accuracy than maize early growth stage. In order to estimate the LAI for maize under different disease grades, UAV multi-spectral image data were used based on the results of disease classification. Four integrated learning models were constructed to estimate the LAI of different disease grades. The result accuracy (rRMSE) of the LAI estimation model was 19.11% (GBDT), 15.94% (LightGBM), 14.51% (RFR) and 15.45% (XGBoost), respectively. The XGBoost model had the best estimation result, and the accuracy of rRMSE: 15.19% (Mild), 17.46% (Moderate), 9.12% (Severe) and 9.63% (No resistant) under different disease grades. The LAI estimation model generally had little difference in the estimation accuracy of maize LAI in the early and middle stages of the disease (disease grade 1 ~ 7). The accuracy of maize LAI estimation results was quite different for maize samples with extremely serious disease, and disease grades in the field would affect the accuracy of maize LAI estimation.

Key words: maize disease; LAI; UAV; hyperspectral; multispectral

0　引言

快速精准获取种质资源和育种材料表型有助于提升种质资源鉴定和育种材料种植规模，进而提升作物种植资源鉴定和育种效率。当前作物种质资源鉴定和育种过程中的表型参数获取主要依靠人工调查、破坏性取样测量或手持仪器逐个小区进行测量，这两种方法效率低、工作量大，且使用手持设备获取表型参数对小区面积有一定要求，增加了大量额外工作，已成为限制作物种质资源鉴定和育种效率的瓶颈[1]。同时，传统的人工表型鉴定方法费时费力，主观性强，缺乏统一的标准[2]。

无人机(Unmanned aerial vehicle，UAV)遥感具有方便快捷、可灵活搭载多种传感器、成本低等特点，基于无人机遥感数据精准提取田间作物种质资源和育种材料表型参数逐渐成为田间作物表型鉴定研究的热点[3-4]。无人机搭传感器是目前大田作物表型分析的主流高通量工具[5]。利用无人机作物表型平台进行大范围观测，获取时间、空间和光谱高分辨率的遥感影像，有助于解决传统人工表型观测的难点[6]。无人机常见可携带的传感器有可见光数码相机、多光谱、高光谱、热红外以及 LiDAR，可以对作物的物理形态、含水率、叶绿素、氮素含量等生物生化性状进行快速准确的估算[7-8]。

叶面积指数(Leaf area index，LAI)与作物产量密切相关，是作物种质资源鉴定和新品种选育的重要指标之一。国内外学者围绕 LAI 遥感反演开展了大量研究，按照所用方法当前基于无人机遥感数据的作物 LAI 反演研究主要可以分为 3 类：① 统计模型方法，基于光谱特征、纹理特征等与 LAI 之间的关系，利用统计回归方法构建 LAI 反演模型[9-10]。② 物理模型法，在辐射传输模型基础上建立模型。通过光子传输模拟冠层辐射传输过程，建立光谱反射率与冠层物理参数模型，通过观测地表反射率反演估算叶面积指数光谱贡献参量[11-13]。③ 深度学习模型，目前广泛应用于 LAI 的测定，采用非线性拟合的神经单元，可以从元数据中提取更深层次的信息，有效提高 LAI 的反演精度[14-15]。无人机所采集影像数据，可以根据不同的数据来源，灵活选择叶面积指数估算模型。但当前作物 LAI 遥感反演研究主要针对大田生产以及生态分析，针对作物种质资源鉴定和育种材料的 LAI 反演研究较少。

在作物种质资源鉴定和育种过程中，由于不同材料的抗病等级不同，某些材料的叶片上病害时常发生，叶片出现病斑时作物冠层光谱会发生相应变化，进而影响作物冠层理化参数遥感反演精度[16]。以往的研究中很少考虑病害对 LAI 反演的影响，因此，当田间种质资源和育种材料小区发生病害时，目

前的 LAI 遥感反演模型适用性有待分析和验证[17]。优化 LAI 估算模型的一个思路是考虑不同田间病害胁迫条件下,讨论 LAI 反演模型的鲁棒性。

综上,本文以黄淮海地区玉米种质资源和育种材料为研究对象,通过人工接种黄淮海地区常见的小斑病(Curvularia leaf spot disease,GLS)和弯孢菌叶斑病(*Curvularia lunata*)小区试验[18-19],获取健康以及不同病害严重程度下玉米 LAI、叶片高光谱和无人机玉米冠层多光谱数据。利用 K 近邻算法(K-nearest neighbours,KNN)、支持向量机(Support vector machine,SVM)、梯度提升分类树(Gradient boosting decision tree,GBDT)、决策树(Decision tree,DT)4 种机器学习方法,基于高光谱数据构建病情等级分类模型并进行比较;利用随机森林(Random forest,RF)、GBDT 回归树、极端梯度增强算法(Extreme gradient boosting,XGBoost)、轻量梯度提升机(Light gradient boosting machine,LightGBM)4 种集成学习方法,基于无人机玉米冠层多光谱数据构建玉米 LAI 反演模型并进行比较;分析不同病情等级对 LAI 反演的影响。

1 材料与方法

1.1 试验设计

田间试验在河南省新乡市七里营镇中国农业科学院新乡综合试验基地(图 1)进行。该试验基地地处暖温带大陆性季风气候。降水多集中在夏季 7、8 月间,年均降水量为 548.3 mm,年均蒸发量为 1 908.7 mm。玉米生长阶段太阳光线充足,年均日照时间为 2 407.7 h,全年无霜期约为 201 d。试验区海拔 70~82 m,年均气温 14.1℃。

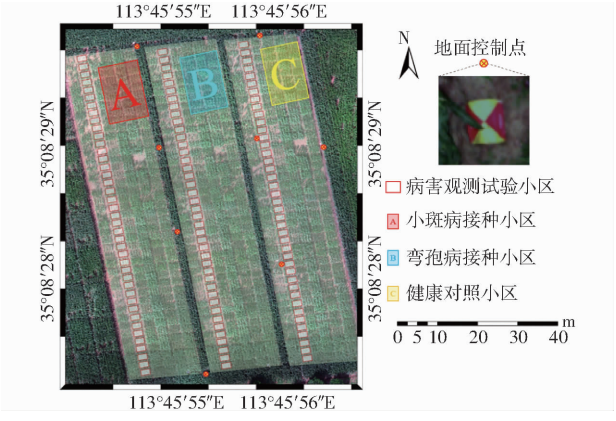

图 1 2021 年玉米病害试验区位置

Fig. 1 Location of maize disease experiment in 2021

试验区玉米的播种方式为行播种,灌溉方式为大水漫灌。田间在播种前施加基肥(尿素、过磷酸钙和硫酸钾),其中包含了硫酸钾(K_2SO_4,52%,12 kg/hm^2)、尿素(N,46%,200 kg/hm^2)以及过磷酸钙($Ca(H_2PO_4)_2$,12%,90 kg/hm^2)。播种时间为 2021 年 6 月 15 日。在田间设置了两种不同颜色的地面控制点,以方便图像进行配准工作。在布设 18 个地面控制点时,尽量避开玉米叶片的遮挡。

试验区东西总长 52 m,南北总长 81.75 m(包括保护行)。试验共有 3 个重复,每个重复中共设置了 246 个不同的玉米自交系品种。在每个重复中选择了 41 个玉米品种小区作为本研究的目标样本,共计 123 个样本小区。由于玉米正常生长会占据预留的过道空间,因此每个玉米品种小区南北方向实际为 1.35 m(株间距 22.5 cm,6 株),设置 57.5 cm 长的过道,余下的空置地补种了保护行玉米。小区东西方向为 2.4 m(行间距 60 cm,4 行),设置 0.6 m 宽的过道。为了防止 2 种病害互相感染,在 2 个重复试验间设置了 3 m 的玉米保护行。在重复试验 1(图 1 中 A 区)中接种了玉米小斑病(Curvularia leaf spot disease),重复试验 2(图 1 中 B 区)中接种了玉米弯孢菌叶斑病(*Curvularia lunata*),重复试验 3(图 1 中C 区)为健康对照组。

1.2 数据获取与预处理

1.2.1 田间地面数据获取

玉米病害试验于 2021 年 8 月 3 日 18:00—21:00 进行。采用电动喷雾器人工接种的方式,在田间接种了玉米小斑病和弯孢病。病害接种后,在玉米抽雄期(Tasseling stage, VT)、吐丝期(Silked stage,R1)、籽粒建成期(Blister stage,R2)和乳熟期(Milk stage,R3)对所选取的 123 个玉米材料小区进行了病情调查、LAI 测量、叶片尺度高光谱测量和无人机数据获取等。采用了相对的数据处理方法,根据不同的病斑面积,将不同的玉米病害小区病情指数等级(Disease index, DI)划分为 1(正常)、3(轻微)、5(中度)、7(重度)和 9(不抗病)5 个等级。具体病情等级描述见表 1。

表 1 玉米叶片病害级别划分标准

Tab. 1 Classification standard of maize leaf disease

病情指数等级	症状描述
1	叶片上无病斑或仅在穗位下部叶片上有零星病斑,病斑面积占叶面积小于等于 5%
3	穗位下部叶片上有少量病斑,病斑面积占叶面积 6%~10%,穗位上部叶片有零星病斑
5	穗位下部叶片上病斑较多,病斑面积占叶面积 11%~30%,穗位上部叶片有少量病斑
7	穗位下部叶片或穗位上部叶片有大量病斑,病斑相连,病斑面积占叶面积 31%~70%
9	叶片基本为病斑覆盖,叶片枯死

病害调查时,每个玉米小区共调查 3 株,每株玉

米调查了穗位叶及其上下 2 叶的病情指数，取其平均值作为小区的平均玉米病情指数。病情指数计算公式为

$$DI = \frac{\sum L_m D_m}{\sum L_n D_{\max}} \times 100\% \quad (1)$$

式中　DI——病情指数

L_m——每个病害等级的叶片数

D_m——病情相对级数值

L_n——左右被调查叶片的总数

$D_{\max}$——叶片样本中病害等级的最大值

试验采集了玉米叶片尺度 ASD 高光谱数据，用于不同玉米种质资源的抗病性分类。地面高光谱数据采用 ASD FieldSpec PRO 4 型（Analytical spectral devices, Inc.，美国）地面非成像高光谱仪，在调查 3 株玉米病情等级固定叶片位置的 1/3、1/2 和 2/3 处采集。每个小区采用带有主动光源的高光谱叶片夹夹在叶片上（图 2a），并用便携式计算机对高光谱进行及时定标（图 2b）。每个小区观测 3 株玉米的固定叶片（图 2d）。

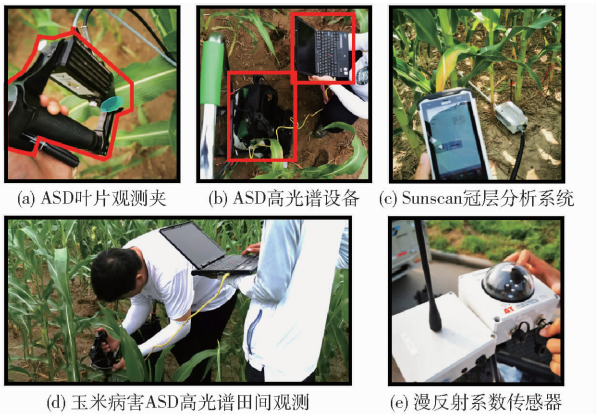

(a) ASD叶片观测夹　(b) ASD高光谱设备　(c) Sunscan冠层分析系统

(d) 玉米病害ASD高光谱田间观测　(e) 漫反射系数传感器

图 2　田间病害及 LAI 数据采集

Fig. 2　Maize disease and hyperspectral data and leaf area index collection

玉米 LAI 采用 Sunscan 冠层分析系统（图 2c）采集，通过漫反射系数传感器（图 2e）测量冠层截获的光合有效辐射量，采用比尔定律计算实际玉米 LAI。由于叶片的不同状态，如健康叶片、病叶、老叶和死叶等对光的透光率不同。同一品种不同病情等级下，所测量的 LAI 也有一些差异。但是本研究主要是考虑大田种植条件下，分析玉米 LAI 实际测量情况，为了统一观测标准，在玉米冠层底部，贴近地面的相同位置进行测量。由于材料小区面积小，植株数量也较少，同时观测频率也较大，因此本研究没有对每个小区进行破坏性取样，按直接测量法观测玉米 LAI。Sunscan 冠层分析系统采集玉米田间叶面积指数采集时间设置在 10:00—14:00，此时光线稳定充足，适合 LAI 观测。为了确保数据的稳定性，在田间分别于播种行方向夹角 0°、45°、90°和 135°方向对玉米叶面积指数进行了观测，每个方向采集 3 次 LAI 数据。最后将采集到的 12 组 LAI 数据求平均值作为玉米小区实际 LAI。玉米各生育期病害与 LAI 观测值如图 3 所示。

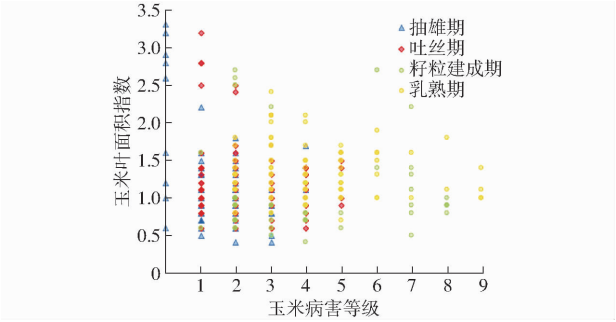

图 3　玉米各生育期病害等级与 LAI 观测值

Fig. 3　Diseases and LAI observations in different growth stages of maize

1.2.2　无人机数据采集

本研究采用 DJI Matrice M600 Pro 型（深圳市大疆创新科技有限公司）六旋翼电动无人机（图 4a）。无人机内置专业级 A3 Pro 飞行控制系统、配备 3 套 IMU 和 GNSS 模块、Lightbridge－2 图像传输系统，图像传输距离最远可达 5 km；标配 6 块 TB47S 型智能电池，参数为 4 500 mA·h、22.2 V；悬停精度为水平 1.5 m，垂直精度为 0.5 m；最大飞行速度为 18 m/s，轴距为 1 133 mm，飞行载质量 6 kg；挂载了 Ronin－MX 型三轴摄影云台，特有的滑环系统使得云台可以 360°连续旋转，搭配 DJI SRW－G 型近距离无线图传设备使用。Ronin－MX 型云台内置的 IMU 精准测量后反馈到处理器，从而保证云台抖动量控制在 ±0.02°以内。这意味着摄影云台的三轴都在运动状态时，Ronin－MX 型云台依然可以获得稳定流畅的画面。云台采用 LiPo 电池，容量为 1 580 mA·h，电压为 14.4 V，整体质量为 2.77 kg。

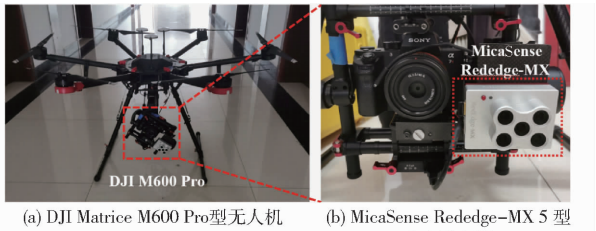

(a) DJI Matrice M600 Pro型无人机　(b) MicaSense Rededge-MX 5 型多光谱相机

图 4　无人机数据采集平台和多光谱传感器

Fig. 4　UAV data acquisition platform and multi-spectral sensor

本试验采用 MicaSense Rededge－MX 5 型通道多光谱相机作为数据采集传感器（图 4b）。多光谱（1 280 像素 ×960 像素）每秒捕获 1 次（所有波段），12 bit RAW，231.9 g，8.7 cm ×5.9 cm ×4.54 cm，可

以获取蓝光波段、绿光波段、红光波段、红边波段和近红外波段。多光谱相机视场角为 47.0°×37.0°，其中心波长以及波段范围如表 2 所示。

表 2 多光谱传感器波段范围

Tab. 2 Band range of multispectral sensor nm

多光谱相机波段	中心波长	光谱波段范围
蓝光通道	475	-20~20
绿光通道	560	-20~20
红光通道	668	-10~10
红边通道	717	-10~10
近红外通道	840	-40~40

1.2.3 数据预处理

无人机飞行实验设置在晴朗无云的天气条件下，采集时间为 10:00—14:00，飞行高度设置为 50 m，飞行速度为 2 m/s，航向和旁向重叠度为 85%。田间小区周围设立了 18 个不同颜色的航空标识参照物。地面像控点采用高精度的 GPS 设备获取这些参考点的中心 GPS 坐标信息，用于后期影像配准。在无人机起飞前和降落后，拍摄了多光谱定标参考板，用于无人机多光谱数据的辐射校正和反射率转换。反射率转换公式为

$$\rho_1 = \frac{R_1}{R_2}\rho_2 \tag{2}$$

式中 R_1——玉米冠层多光谱影像辐射亮度

R_2——定标板的辐射亮度

ρ_1——玉米冠层光谱反射率

ρ_2——定标板光谱反射率

无人机搭载多光谱相机在玉米的不同生长阶段共拍摄了 4 期影像数据。无人机获取影像数据之后，采用 Agisoft PhotoScan（Agisoft LLC，俄罗斯）软件对无人机影像进行拼接、辐射定标和反射率转换。将影像和相对应的定位定姿系统导入软件中，多光谱影像拼接前，采用拍摄的无人机定标板影像以及其反射率对原始影像进行辐射校正。将最终的影像拼接结果保存为“.GeoTIFF”格式文件。无人机飞行任务设置以及多光谱影像分辨率在玉米各生育阶段设置如表 3 所示。

表 3 无人机田间飞行试验参数设置

Tab. 3 Parameter setting of UAV field flight test

飞行日期	玉米生长阶段	航向重叠度/%	旁向重叠度/%	飞行时间/min
2021 年 8 月 11 日	抽雄期	85	85	26
2021 年 8 月 19 日	吐丝期	85	85	26
2021 年 8 月 27 日	籽粒建成期	85	85	26
2021 年 9 月 2 日	乳熟期	85	85	26

利用采集的高光谱数据构建了与玉米叶片叶绿素和氮素相关的植被指数：①叶绿素敏感指数。RVI1[20]、NDVI1[21]、NDVI2[21]、PRI[22]、VOG1[23]、VOG2[23]、$CI_{red\text{-}edge}$[24]、CI_{green}[24]、GMI-1[25]、GMI-2[25]、ZM[26]、RI-1db[27]、RI-2db[27]、RI-half[27]、ChI-NDI[20]、MCARI[28]、MTCI[29]。②氮含量敏感光谱指数。RVI_2、RVI_3、$NDVI_3$、NDVI、$mRVI_{705}$、mND_{705}、$NDVI_{705,1092}$。③比叶质量光谱指数。NDLMA[30]、NDMI[31]。在冠层尺度上，利用无人机多光谱影像的可见光波段构建了与叶片颜色相关的植被指数：INT[32]、GRVI[33]、NDI[34]、WI[35]、IKAW[36]、GLI[37]、GLI2[37]、VARI[38]、ExR[39]、ExG[39]、ExB[39]、ExGR[39]、VEG[40]、IPCA[41]、CIVE[41]、COM[42]、RGBVI[43]、MGRVI[44]，并通过红边和近红外波段构建了与叶片光谱变化相关的植被指数：DVI[33]、EVI[45]、GNDVI[46]、$VI_{(nir/green)}$[25]、$VI_{(nir/red)}$[47]、$VI_{(nir/rededge)}$[47]、ln_{RE}[48]、MSAVI[49]、MSAVI2[49]、OSAVI[50]、MTVI2[51]、NDRE[20]、NDVI[52]、MSR[53]，将构建的植被指数作为玉米病情等级监测和 LAI 反演的光谱特征。本文主要技术路线如图 5 所示。

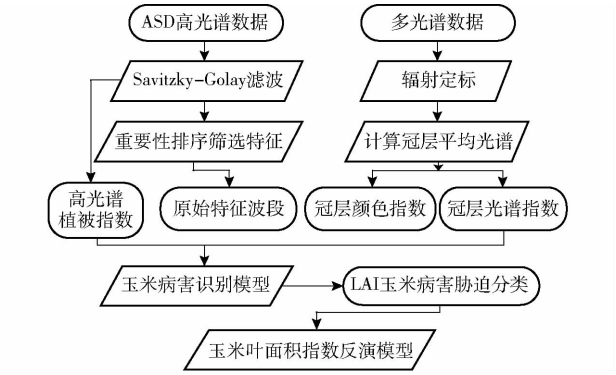

图 5 数据处理流程图

Fig. 5 Data processing flowchart

1.3 病害识别与 LAI 反演模型

1.3.1 置换重要性

本研究基于“置换检验的思想”对特征重要性进行检测，即在模型拟合后，数据表格中某一列数据随机排序，其余特征保持不动，看其对预测精度的影响[54]。采用 Python 的 scikit-learn 0.232 库实现置换重要性操作流程。在每个玉米生育时期，筛选出 30 个玉米对应病害的重要性特征，分别构建不同玉米时期下的 LAI 预测模型。本研究所采用的编译环境为 Python 3.7（Python Software Foundation，美国），采用的集成开发环境为 Pycharm 2021.2.1（JetBrains，捷克共和国）。本研究涉及有关影像的栅格计算均采用的是 Python 3.7-GDAL 2.4.1（Geospatial Data Abstraction Library），涉及的统计计

算均以 Python 3.7 - Pandas 1.1.5 拓展模块中的功能实现。

1.3.2　病害识别模型

玉米病害识别模型采用 4 种分类模型，对 2 种玉米叶斑病不同病情等级进行了分类研究。研究构建了 K 近邻算法（KNN）[55]、支持向量机（SVM）[56]、梯度提升分类树（GBDT）[57]、决策分类树（DT）[58] 4 个分类模型，基于地面高光谱和冠层多光谱数据对玉米病害进行分类研究。使用欧氏距离（Euclidean distance）作为判别基准建立 KNN 病害识别模型[59]。支持向量机采用线性核函数（Linear kernel function）、GBDT 分类树算法采用偏差核函数（Deviance）以及决策树算法采用基尼系数作为决策数最佳分支点指标，对病害数据进行分类研究。基于 ASD 高光谱构建光谱指数，构建病害识别模型对病害等级进行分类研究。

1.3.3　叶面积指数反演模型

在玉米病害识别结果的基础上，构建了不同病情等级玉米 LAI 数据集，分析病害胁迫下叶面积指数反演精度。反演模型主要构建了 4 种回归模型，即随机森林回归（RFR）[60]、梯度提升回归树（GBDT）[61]、极端梯度增强算法（XGBoost）[61] 和轻量梯度提升机（LightGBM）[62] 机器学习模型对不同病害胁迫下玉米 LAI 进行反演研究。研究采用了随机搜索（Randomized - Search CV）算法，对 4 种机器学习模型的超参数进行迭代优化。由于每个时期玉米长势和病情等级不同，因此每个玉米生育期分别进行了模型超参数优化步骤，最后评估了 4 个 LAI 估算模型，选择最佳的模型超参数，每个模型超参优化的项目如表 4 所示。将训练集和验证集的数据按比例 2∶1进行分配，挑选最佳的 LAI 估测模型，并评估不同模型的性能。

表 4　玉米叶面积指数反演模型超参优化

Tab.4　Super-parameter optimization of maize LAI estimation model

模型	超参数
极端梯度增强算法	最大迭代次数，学习率，树的最大深度，权重最小总和
轻量梯度提升机	最大迭代次数，学习率，树的最大深度，权重最小总和
梯度提升回归树	最大迭代次数，学习率，树的最大深度，权重最小总和
随机森林回归	最大迭代次数，树的最大深度，分割所需最小样本，权重最小总和

1.4　精度评估

为了在相同标准下评估不同模型的性能，采用 66.7% 的数据作为模型的训练样本，其余 33.3% 的样本作为验证集。分类模型和估测模型分别计算总体精度（Over accuracy，OA）、决定系数（Coefficient of determination，R^2）、均方根误差（Root mean square error，RMSE）、相对均方根误差（Relative root mean square error，rRMSE）和绝对均方根误差（Mean absolute error，MAE）用于评估模型的性能和准确性。

2　结果与评价

以 123 个玉米小区不同时期观测到的冠层多光谱数据为基础，通过对不同时期病害的光谱分析，构建了与玉米病害相关的植被指数，同时构建分类模型对田间冠层尺度的玉米品种抗病性进行识别探究。同时，基于病害分类结果，探讨了在不同玉米病害等级胁迫下，集成学习方法在不同时期估算玉米 LAI 的鲁棒性。

2.1　光谱数据分析

在叶片尺度下，高光谱信息对于叶面上的细胞结构较为敏感（图 6）。不同的病害程度其光谱反射率显示出了明显的差异。当玉米叶片受到病害侵染时，往往出现不同尺寸、形状的病斑症状，破坏了原有的细胞结构。病害所导致的叶绿素下降和叶片干枯等现象，使得玉米叶片光谱反射率逐渐增高。当病斑出现，叶绿素被破坏，进而导致病斑周围干枯。此时，叶绿素在可见光波段对红光和蓝光的吸收下降，进而导致可见光波段整体反射率升高。但是在

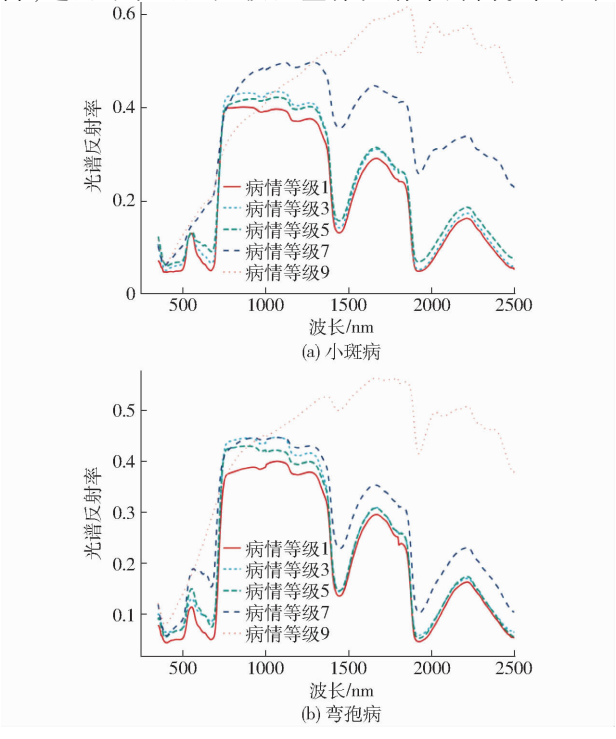

图 6　叶片尺度玉米弯孢和小斑病病情等级高光谱反射率

Fig.6　Hyper-spectral reflectance of maize Curvularia and leaf spot disease grades at leaf scale

冠层尺度,多光谱随着病情程度的增加,光谱反射率在逐渐下降。

通过分析多光谱影像的地物光谱反射率,当病害侵染玉米严重时,会导致玉米叶片枯死。同一生育期下,冠层光谱玉米感病组和健康对照组有明显的光谱差异(乳熟期,图 7)。当玉米患病时,病害病症往往从底部向上发展,上层叶片容易将下层叶片遮挡。由于无人机是正射影像,因此很难在早期对病害进行有效监测。在玉米发病中后期,冠层上部叶片也开始发病,此时影像中的病害特征明显,从无人机多光谱影像中更容易提取到病害特征。同时由于多光谱影像波段是宽波段反射率,因此与高光谱所测得光谱有一些差异。

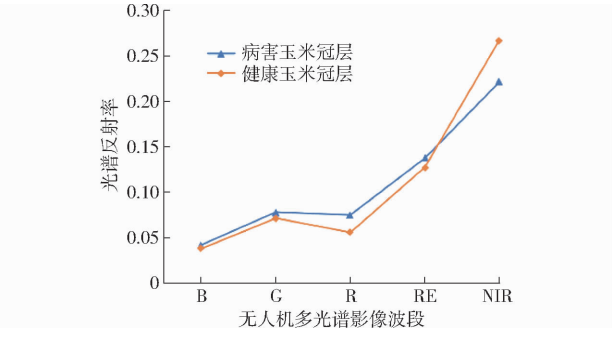

图 7 病害和健康对照组玉米冠层光谱反射率

Fig. 7 Canopy spectral reflectance of maize in susceptible and healthy control groups

绿色叶片像素在影像中的占比减少,因此导致冠层尺度下反射率降低。在提取多光谱影像信息时,构建 VEG(Vegetable index)指数,从影像中剔除了土壤信息,减少其对光谱信息的影响[63-64],土壤、玉米雄穗和冠层光谱曲线如图 8 所示。

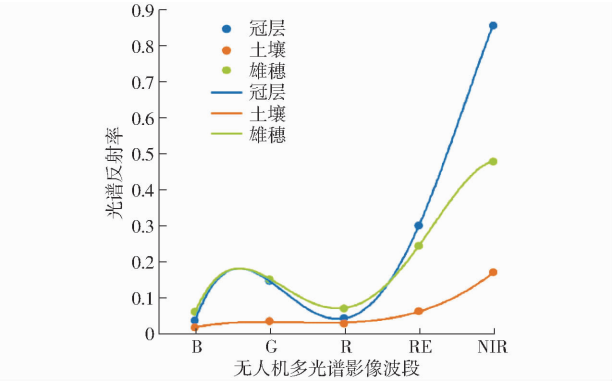

图 8 冠层多光谱影像不同地物光谱反射率

Fig. 8 Spectral reflectance of different ground objects in canopy multispectral images

2.2 玉米病害检测识别结果

本文基于不同玉米病情等级下所显示的光谱差异,构建了 4 种模型分类模型(KNN、GBDT、SVM 和 DT)对不同时期下玉米病情等级进行识别。病害识别模型采用叶片尺度玉米病害高光谱构建的植被指数作为敏感特征。玉米各个生育期下,不同玉米病情等级模型识别结果如表 5 所示。在玉米病害接种的早期,由于玉米病害症状不明显(接种但未有明显的症状),很容易与健康玉米品种显示出相同的叶片结构,因此在病害早期,识别精度较低。随着玉米病害的不断发展,玉米叶斑病症状逐渐加重,不同病情等级叶片差异逐渐明显,4 种病害识别模型对病情等级识别精度逐渐提升,在 9 月 2 日时模型平均精度最高。4 个玉米病害识别模型在玉米不同生育期平均识别精度为:63.44%(8 月 11 日)、60.06%(8 月 19 日)、66.16%(8 月 27 日)、80.19%(9 月 2 日)。在整个生育期下,GBDT 集成学习分类模型显示了更强的鲁棒性,在玉米整个生育期对玉米病害显示了良好的分类性能(总体精度为 84.72%)。其他 3 个模型在整个玉米生育期病害识别平均精度分别为 47.67%(SVM)、55.05%(KNN)、83.02%(DT)。

表 5 玉米病害全生育期识别结果

Tab. 5 Identification results of whole growth period of maize diseases

数据采集日期	病害识别模型	决定系数	均方根误差	绝对均方根误差	总体精度/%
8 月 11 日	SVM	0.25	0.96	0.70	45.57
	KNN	0.30	0.67	0.44	51.90
	GBDT	0.43	0.51	0.26	80.34
	DT	0.59	0.58	0.33	75.95
8 月 19 日	SVM	0.24	0.87	0.68	31.71
	KNN	0.35	0.89	0.71	40.24
	GBDT	0.63	0.73	0.46	85.37
	DT	0.53	0.80	0.50	82.93
8 月 27 日	SVM	0.57	1.07	0.71	39.02
	KNN	0.35	0.82	0.54	54.88
	GBDT	0.65	0.82	0.54	84.15
	DT	0.60	0.85	0.57	86.59
9 月 2 日	SVM	0.45	0.80	0.57	74.39
	KNN	0.64	0.71	0.50	73.17
	GBDT	0.85	0.63	0.39	86.59
	DT	0.85	0.57	0.32	86.59

随着玉米不断生长以及病情不断加剧,分类模型对玉米病害的识别精度逐渐提高,结果如图 9 所示。4 个分类模型在 9 月 2 日时,对病害的分类精度均达到最好。玉米病害接种后,随着病情不断发展,叶片上的病情越发严重。GBDT 模型在 8 月 11 日和 8 月 19 日取得了最佳精度(OA 分别为 80.34%、85.37%),DT 模型在 8 月 27 日和 9 月 2 日取得最佳病害分类精度(OA 分别为 86.59%、86.59%)。病害早期误差较大,此时试验田多半在

病情早期，健康叶片占比较大，轻微病害光谱与健康叶片光谱差异不大。随着病害侵染的加深，玉米叶片病斑面积逐渐增加，导致较大的光谱差异，这也是导致在玉米物候后期，病害识别准确率上升的原因。

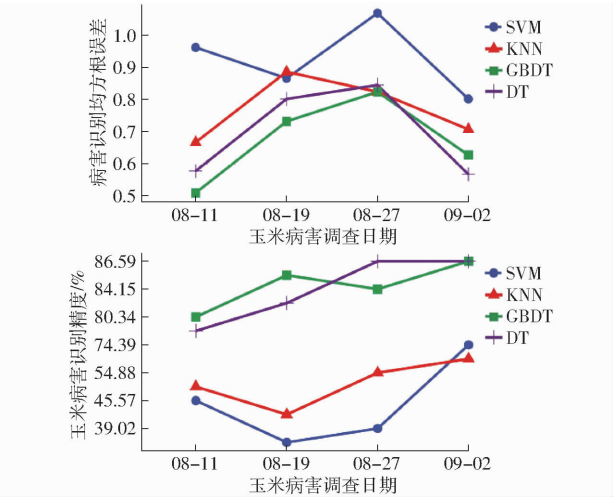

图 9　不同玉米生育期下病害识别分类误差

Fig. 9　Disease identification and classification errors at different maize growth stages

在玉米病害最佳估算时期（9 月 2 日），4 个病害分类模型识别结果如表 6 所示。混淆矩阵表格显示，DT 模型和 GBDT 模型识别结果分类精度相同，DT 模型的 RMSE 比 GBDT 模型 RMSE 略低。SVM 和 KNN 模型仅对中度病害识别精度较高，对其他玉米病情等级样本识别精度不佳。GBDT 和 DT 模型对所有不同病情等级识别精度较高。同时 DT 模型取得了最低的 rRMSE，为 14.35%，证明利用高光谱构建的与病害相关的植被指数可以用于玉米病情等级的准确分类。

表 6　玉米病害监测模型最佳玉米生育期分类识别结果

Tab. 6　Classification and recognition results in optimal growth stage of maize disease monitoring model

模型	病害严重程度	样本数目				总体精度/%	均方根误差
		轻微	中度	重度	不抗病		
SVM	1～2	0	0	0	0	74.39	0.80
	3～5	11	60	6	3		
	6～8	0	0	0	0		
	9	0	0	0	1		
KNN	1～2	7	7	1	0	73.17	0.71
	3～5	6	51	4	2		
	6～8	0	1	1	1		
	9	0	0	0	1		
GBDT	1～2	7	3	0	0	86.59	0.63
	3～5	5	57	3	0		
	6～8	0	0	3	0		
	9	0	0	0	4		
DT	1～2	9	4	0	0	86.59	0.57
	3～5	3	53	1	0		
	6～8	0	3	5	0		
	9	0	0	0	4		

2.3　病害胁迫下玉米 LAI 估算

依据冠层尺度多光谱影像所构建的植被指数，构建了 4 种机器学习回归模型，对病害胁迫下的玉米 LAI 进行估算，结果如表 7 所示。

表 7　玉米不同生育期下 LAI 模型估算结果

Tab. 7　Estimation results of LAI model at different growth stages of maize

数据采集日期	病害识别模型	决定系数 R^2	均方根误差	相对均方根误差/%	绝对均方根误差
08－11	GBDT	0.78	0.40	21.86	0.33
	LightGBM	0.78	0.33	20.02	0.26
	RFR	0.46	0.20	18.36	0.16
	XGBoost	0.39	0.26	17.27	0.22
08－19	GBDT	0.86	0.34	18.32	0.28
	LightGBM	0.86	0.24	14.52	0.19
	RFR	0.90	0.14	12.38	0.11
	XGBoost	0.87	0.22	14.54	0.19
08－27	GBDT	0.85	0.35	18.94	0.28
	LightGBM	0.92	0.23	13.80	0.19
	RFR	0.86	0.15	13.36	0.12
	XGBoost	0.91	0.22	14.67	0.17
09－02	GBDT	0.91	0.32	17.31	0.26
	LightGBM	0.87	0.26	15.40	0.20
	RFR	0.87	0.15	13.95	0.13
	XGBoost	0.75	0.23	15.32	0.19

在不同玉米生育期下病害识别模型平均 rRMSE 分别为 19.38%（8 月 11 日）、14.94%（8 月 19 日）、15.19%（8 月 27 日）和 15.45%（9 月 2 日）。在病害中后期，模型对病害识别性能相似。但是不同病害识别模型，在整个生育期对病害识别的精度有所不同。其中最佳的病害识别模型是 RFR（rRMSE 为 14.51%），其他 3 个模型 rRMSE 分别为 19.11%（GBDT）、15.94%（LightGBM）和 15.45%（XGBoost）。

以 9 月 2 日玉米 LAI 反演结果为例，基于玉米不同病情等级，将玉米 LAI 分成了 4 个子集以分析不同的病害胁迫对估算 LAI 的影响（表 8）。玉米 LAI 最佳估算时期中 XGBoost 模型在玉米轻微发病和严重发病时，估算 LAI 精度最高，相对均方根误差 rRMSE 分别为 15.19% 和 9.12%。LightGBM 模型在玉米中度病害时，估算 LAI 精度最好，rRMSE 为 15.52%。GBDT 模型在玉米不抗病的品种样本下，估算精度最高，rRMSE 为 7.55%。从结果上看，4 种模型在病害早期和中期（病情等级 1～7）对玉米 LAI 估算精度相差不大。但是对病情极其严重的玉米样本，其玉米 LAI 估算结果精度差异较大。考虑

表 8 不同病害胁迫下玉米验证集 LAI 估算结果

Tab. 8 Estimation results of maize LAI in optimal growth stage under different disease stresses (validation dataset)

分类模型	病情等级	R^2	RMSE	rRMSE/%	MAE
GBDT	轻微	0.83	0.19	15.57	0.15
	中度	0.43	0.22	18.38	0.18
	重度	0.51	0.18	12.40	0.16
	不抗病	0.46	0.08	7.55	0.06
LightGBM	轻微	0.82	0.22	17.85	0.18
	中度	0.49	0.18	15.52	0.14
	重度	0.48	0.15	10.75	0.14
	不抗病	0.25	0.31	30.60	0.28
RFR	轻微	0.88	0.20	15.96	0.16
	中度	0.38	0.21	18.04	0.17
	重度	0.51	0.18	13.06	0.17
	不抗病	0.21	0.22	21.61	0.19
XGBoost	轻微	0.82	0.19	15.19	0.15
	中度	0.60	0.21	17.46	0.17
	重度	0.64	0.13	9.12	0.10
	不抗病	0.37	0.10	9.63	0.10

到玉米不抗病的样本较少,模型对其训练度不够,因此造成玉米病害十分严重时,模型精度差异较大。

2.4 玉米病害时空分布

图 10 显示了利用无人机多光谱影像估算玉米 LAI 空间分布图。玉米育种过程中需要经过多代选择比较才能选育出优良的自交系品种。但是由于其严格的自花授粉,一般都产生活力衰退的现象,表现为植株变得弱小,并出现一些少见的畸形性状。这是导致自交系普遍 LAI 较低的原因之一。在接种完病害后,小斑病和弯孢病对玉米叶面积指数的影响也不一致,与健康对照组相比,多数的玉米自交系品种在同时期 LAI 都有所下降。其中最好的玉米抗病性品种为科沃 674 和新农奇 6003,对玉米病害有较强的抵抗性。在接种后的 1 个月内始终只有零星病斑,病情等级为 1.27。最不抗病的品种为 ZM148,最终病情等级为 9。玉米植株的抗病性与 LAI 显著相关,抗病性越高,玉米生长后期 LAI 越高。病害对叶片结构破坏,会导致 LAI 下降明显,影响玉米正常的生长发育,因此在大范围育种材料中,筛选抗病性强、LAI 高的玉米品种,可以有效提高玉米育种筛选效率以及时间,加快表型分析进度,提升整理表型研究进程。

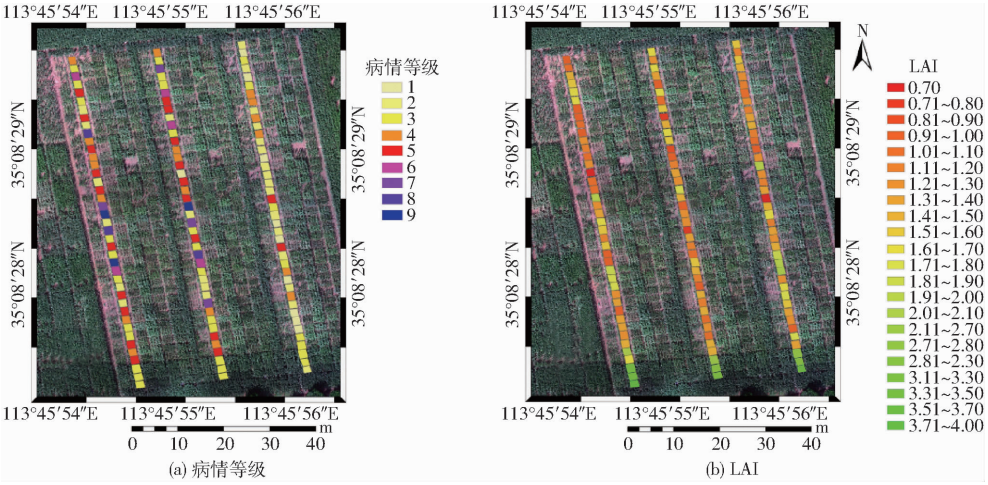

图 10 玉米病情等级和 LAI 模型估算结果时空分布(9 月 2 日)

Fig. 10 Spatiotemporal distribution of maize disease level and LAI model estimation results (September 2)

3 讨论

图 11 显示了玉米弯孢病和小斑病两种病害轻微、中度、重度和不抗病 4 种病情等级。玉米病虫害引起的症状,常常与叶片的色素、细胞结构、植物中的液态水等密切相关,但是玉米侵染早期,病症不明显。从病害识别结果上看(表 5),玉米病害早期识别精度不高。但是随着病情不断发展,在玉米生长发育后期,病害识别结果明显优于早期。由于玉米叶绿素遭到破坏,病斑周围出现椭圆形或长方形的病斑,颜色呈黄色或黄褐色[65],此时叶绿素对红光和蓝光的吸收能力下降,光谱的反射率变化明显,这有助于从无人机多光谱影像中提取病害特征。在后期发病严重时,病斑布满了整张叶片,导致叶片提前枯死,进而降低了玉米叶面积指数[66]。同时在玉米生长发育早期,LAI 估算精度较低,此时玉米郁闭程度不高,土壤在影像中的占比较大,提取到的叶片信息较少。随着玉米不断生长,冠层郁闭程度不断提高,在多光谱影像中,玉米叶片信息量逐渐提高,各个反演模型对 LAI 的估算精度也逐渐提升。

本文采用多种特征的方法,相较于王利民等[67]在单个玉米生育期使用一元线性回归估算玉米病害,本文采用的分类模型在全生育期下有很好的鲁棒性。但是,如何在玉米病害侵染早期实现病情等

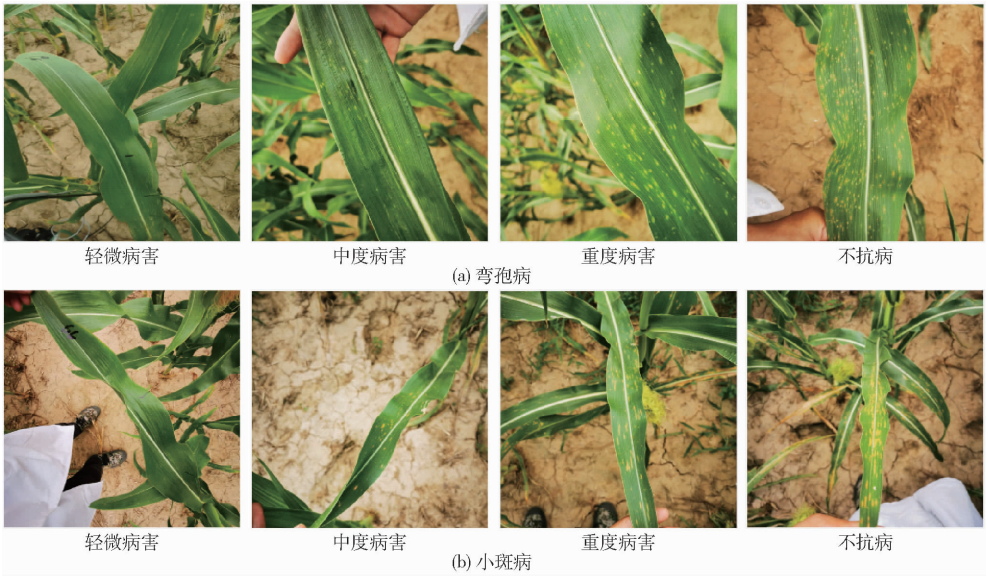

图 11　玉米弯孢病和小斑病病症

Fig. 11　Symptoms of maize leaf *Curvularia lunata* and Curvularia leaf spot disease

级的准确估算，仍然是当前研究的重点。玉米乳熟期与抽雄期 LAI 的比值在玉米病情等级 1、3、5、7、9 时分别为 1.13、0.93、0.86、0.93、0.71，从数据上看随着病情等级的发展，玉米 LAI 下降明显。抗病玉米品种抽雄期相较于乳熟期 LAI 略有增加。抗病性不足的玉米品种，在病害等级 9 时，乳熟期 LAI 仅为抽雄期的 0.71，病害导致玉米底层叶片枯萎死亡，相较于抗病性较强的品种，LAI 下降明显，因此选择高抗病性的品种可以使玉米 LAI 保持正常水平。利用无人机多光谱影像，提取与玉米 LAI 相关的植被指数，相较贺佳等[68]的研究，本文构建了多种集成学习回归模型，针对不同病害胁迫下玉米自交系品种的 LAI 进行准确估算。从结果上看，病情等级越高，LAI 估算结果精度也越高。GBDT 模型对不抗病品种 LAI 估算精度最高，rRMSE 为 7.55%。XGBoost 模型对严重病情等级玉米品种的 LAI 估算结果精度最高，rRMSE 为 9.12%。当病情等级严重时，叶片结构受损严重，叶片枯萎脱落，进而导致叶面积下降。但是由于品种差异，不抗病品种 LAI 数据梯度较大，样本空间丰富，这可能是集成学习模型更容易从特征中估算 LAI 的原因。

4 个集成学习模型对不同病情等级鲁棒性不同。GBDT、LightGBM、RFR 以及 XGBoost 在不同病情等级下，平均 rRMSE 分别为 13.48%、18.68%、17.3% 和 12.85%。4 个模型的误差都在 10% 以上，由于玉米自交系品种之间的差异较大，从影像中提取的特征很难有统一的标准。比如有的品种叶片结构较窄、叶色较深、抗病性强，有的品种叶片结构宽大、叶色较浅、抗病性差，此时两者所提取的有一些植被指数值可能相似，此时模型很难学习到不同样本特征，导致鲁棒性下降。因此，在不同生育期下，在分类误差低于 20% 时，本研究认为已经可以达到工程应用的精度范围。XGBoost 和 GBDT 在不同玉米病害侵染等级的条件下模型鲁棒性较好，其中 XGBoost 显示出了最优的鲁棒性。这与张宏鸣等[69]的研究类似，XGBoost 集成学习模型对玉米 LAI 的估算精度最高。相较于 GBDT 模型只用到一阶导数信息，XGBoost 对代价函数进行了二阶泰勒展开，同时用到了一阶和二阶导数，最终使得 XGBoost 模型的 LAI 估算效果更好。从结果上看，田间不同病情等级胁迫确实是影响 LAI 估算的原因之一。后续研究中，需要探究不同病情等级是如何影响 LAI 准确估算的，以及如何提升 LAI 模型的鲁棒性，以提高估算精度。基于无人机多源遥感影像对玉米叶面积指数精准估算有巨大潜力。然而，为了进一步评估稳健性，这种方法需要添加不同的传感器，在不同的生态位上针对不同的作物类型和大量基因型进行测试。

4　结论

（1）为了分析病害胁迫下，基于无人机多光谱玉米 LAI 的精确估算，本文设计了 3 个玉米重复试验，并通过人工接种玉米病菌的方式，获取了不同病害严重程度的玉米样本。同时测量了不同严重程度的玉米叶片高光谱和冠层多光谱数据，同时采集了不同时期玉米 LAI 数据。通过对不同玉米病情等级的分类，分析了在不同病害胁迫条件下玉米 LAI 的估算精度问题。

（2）采用 KNN、SVM、RF 和 GBDT 分类模型对叶片病害进行分类。病害分类模型在整个玉米生育期

病害识别平均精度分别为 84.72%(GBDT)、47.67%(SVM)、55.05%(KNN)、83.02%(DT)。在玉米病情较严重时,分类精度较高,而在玉米病害侵染早期分类精度低,这仍然是目前玉米病害分类的难点。

(3)以冠层多光谱影像构建玉米 LAI 估算模型,XGBoost 模型在玉米轻微发病和严重发病时,估算 LAI 精度最高,相对均方根误差 rRMSE 分别为 15.19% 和 9.12%。LightGBM 模型在玉米中度病害时,估算 LAI 精度最好,rRMSE 为 15.52%。GBDT 模型在玉米不抗病的品种样本下,估算精度最高,rRMSE 为 7.55%。

(4)4 种模型在病害早期和中期(病情等级 1 ~ 7)对玉米 LAI 估算精度相差不大。但是对病情极其严重的玉米样本,其玉米 LAI 估算结果精度差异较大。其中 XGBoost 对不同病情等级的鲁棒性最强,平均 rRMSE 为 12.85%。

参 考 文 献

[1] CHEN D, NEUMANN K, FRIEDEL S, et al. Dissecting the phenotypic components of crop plant growth and drought responses based on high-throughput image analysis[J]. The Plant Cell, 2014, 26(12): 4636 - 4655.

[2] FURBANK R T, TESTER M. Phenomics-technologies to relieve the phenotyping bottleneck[J]. Trends in Plant Science, 2011, 16(12): 635 - 644.

[3] GONZALEZ-DUGO V, ZARCO-TEJADA P, NICOLÁS E, et al. Using high resolution UAV thermal imagery to assess the variability in the water status of five fruit tree species within a commercial orchard[J]. Precision Agriculture, 2013, 14(6): 660 - 678.

[4] LIEBISCH F, KIRCHGESSNER N, SCHNEIDER D, et al. Remote, aerial phenotyping of maize traits with a mobile multi-sensor approach[J]. Plant Methods, 2015, 11(1): 1 - 20.

[5] BERNI J A, ZARCO-TEJADA P J, SUÁREZ L, et al. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle[J]. IEEE Transactions Geoscience Remote Sensing, 2009, 47(3): 722 - 738.

[6] YANG G, LIU J, ZHAO C, et al. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: current status and perspectives[J]. Frontiers in Plant Science, 2017, 8(1): 1111 - 1137.

[7] ROITSCH T, CABRERA-BOSQUET L, FOURNIER A, et al. New sensors and data-driven approaches—a path to next generation phenomics[J]. Plant Science, 2019, 282(1): 2 - 10.

[8] GÓMEZ-CANDÓN D, VIRLET N, LABBÉ S, et al. Field phenotyping of water stress at tree scale by UAV-sensed imagery: new insights for thermal acquisition and calibration[J]. Precision Agriculture, 2016, 17(6): 786 - 800.

[9] 王翔宇, 杨菡, 李鑫星, 等. 基于无人机可见光谱遥感的玉米长势监测[J]. 光谱学与光谱分析, 2021, 41(1): 265 - 270.
WANG Xiangyu, YANG Han, LI Xinxing, et al. Research on maize growth monitoring based on visible spectrum of UAV remote sensing[J]. Spectroscopy and Spectral Analysis, 2021, 41(1): 265 - 270. (in Chinese)

[10] 徐洪刚, 陈震, 程千, 等. 无人机多源光谱反演大田夏玉米叶面积指数[J]. 灌溉排水学报, 2021, 40(8): 42 - 49.
XU Honggang, CHEN Zhen, CHENG Qian, et al. Leaf area index of summer maize estimated using UAV-based multispectral imageries[J]. Journal of Irrigation and Drainage, 2021, 40(8): 42 - 49. (in Chinese)

[11] VERHOEF W. Light scattering by leaf layers with application to canopy reflectance modeling: the SAIL model[J]. Remote Sensing of Environment, 1984, 16(2): 125 - 141.

[12] 王枭轩, 卢小平, 杨泽楠, 等. 基于 PROSAIL 结合 VMG 模型的冬小麦叶面积指数反演方法[J]. 农业机械学报, 2022, 53(6): 209 - 216.
WANG Xiaoxuan, LU Xiaoping, YANG Ze'nan, et al. Retrieving method for leaf area index of winter wheat by combining PROSAIL model with VMG model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 209 - 216. (in Chinese)

[13] 贠静, 郑逢令, 安沙舟, 等. 基于 PROSAIL 模型的山地草原叶面积指数高光谱反演[J]. 新疆农业科学, 2022, 59(2): 451 - 457.
YUN Jing, ZHENG Fengling, AN Shazhou, et al. Hyperspectral inversion of leaf area index in mountain steppe ecosystems based on the PROSAIL model[J]. Xinjiang Agricultural Sciences, 2022, 59(2): 451 - 457. (in Chinese)

[14] YUAN Q, SHEN H, LI T, et al. Deep learning in environmental remote sensing: achievements and challenges[J]. Remote Sensing of Environment, 2020, 241(1): 111 - 116.

[15] ZHU N, LIU X, LIU Z, et al. Deep learning for smart agriculture: concepts, tools, applications, and opportunities[J]. International Journal of Agricultural and Biological Engineering, 2018, 11(4): 32 - 44.

[16] 李芹英. 气候条件对夏玉米主要病虫害发生的影响[J]. 安徽农学通报, 2021, 27(4): 95 - 96.

[17] 苏红军, 杜培军. 高光谱数据特征选择与特征提取研究[J]. 遥感技术与应用, 2006, 21(4): 288 - 293.
SUN Hongjun, DU Peijun. Study on feature selection and extraction of hyperspectral data[J]. Remote Sensing Technology and Application, 2006, 21(4): 288 - 293. (in Chinese)

[18] WARD J M, STROMBERG E L, NOWELL D C, et al. Gray leaf spot: a disease of global importance in maize production[J]. Plant Disease, 1999, 83(10): 884 - 895.

[19] NEGA A, LEMESSA F, BERECHA G. Distribution and importance of maize grey leaf spot cercospora zeae-maydis (Tehon and Daniels) in south and southwest Ethiopia[J]. J. Plant Pathol Microbiol, 2016, 7(7): 1 - 7.

[20] GITELSON A, MERZLYAK M N. Quantitative estimation of chlorophyll-a using reflectance spectra: experiments with autumn chestnut and maple leaves[J]. Journal of Photochemistry and Photobiology B: Biology, 1994, 22(3): 247 - 252.

[21] 卫亚星，王莉雯. 乌梁素海湿地芦苇最大羧化速率的高光谱遥感[J]. 生态学报，2017，37(3)：841－850.
WEI Yaxing，WANG Liwen. Maximum carboxylation rates of reed in the Wuliangsuhai wetland using hyperspectral remote sensing[J]. Acta Ecologica Sinica，2017，37(3)：841－850.(in Chinese)
[22] PEÑUELAS J，FILELLA I，GAMON J A. Assessment of photosynthetic radiation-use efficiency with spectral reflectance[J]. New Phytol，1995，131(3)：291－296.
[23] MISTELE B，SCHMIDHALTER U. Tractor-based quadrilateral spectral reflectance measurements to detect biomass and total aerial nitrogen in winter wheat[J]. Agron. J.，2010，102(2)：499－506.
[24] GITELSON A A，VIÑA A，CIGANDA V，et al. Remote estimation of canopy chlorophyll content in crops[J]. Geophysical Research Letters，2005，32(8)：93－114.
[25] 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.
[26] ZARCO-TEJADA P J，MILLER J R，NOLAND T L，et al. Scaling-up and model inversion methods with narrowband optical indices for chlorophyll content estimation in closed forest canopies with hyperspectral data[J]. IEEE Trans. Geoscience Remote Sensing，2001，39(7)：1491－1507.
[27] GUPTA R，VIJAYAN D，PRASAD T. Comparative analysis of red-edge hyperspectral indices[J]. Advances in Space Research，2003，32(11)：2217－2222.
[28] DAUGHTRY C S，WALTHALL C，KIM M，et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance[J]. Remote Sensing of Environment，2000，74(2)：229－239.
[29] DASH J，CURRAN P. The MERIS terrestrial chlorophyll index[J]. International Journal of Remote Sensing，2004，25(23)：5403－5413.
[30] FERET J B，FRANÇOIS C，ASNER G P，et al. PROSPECT－4 and 5：advances in the leaf optical properties model separating photosynthetic pigments[J]. Remote Sensing of Environment，2008，112(6)：3030－3043.
[31] WANG L，HUNT JR E R，QU J J，et al. Towards estimation of canopy foliar biomass with spectral reflectance measurements[J]. Remote Sensing of Environment，2011，115(3)：836－840.
[32] AHMAD I S，REID J F. Evaluation of colour representations for maize images[J]. J. Agric. Eng. Res.，1996，63(3)：185－195.
[33] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation[J]. Remote Sensing of Environment，1979，8(2)：127－150.
[34] WOEBBECKE D M，MEYER G E，VON BARGEN K，et al. Plant species identification，size，and enumeration using machine vision techniques on near-binary images[C]//Proceedings of the Optics in Agriculture and Forestry，1993.
[35] WOEBBECKE D M，MEYER G E，VONBARGEN K，et al. Color indexes for weed identification under various soil，residue，and lighting conditions[J]. Trans. Am. Soc. Agric. Eng.，1995，38(1)：259－269.
[36] KAWASHIMA S，NAKATANI M. An algorithm for estimating chlorophyll content in leaves using a video camera[J]. Ann. Bot.，1998，81(1)：49－54.
[37] LOUHAICHI M，BORMAN M M，JOHNSON D E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat[J]. Geocarto. Int.，2001，16(1)：65－70.
[38] GITELSON A A，KAUFMAN Y J，STARK R，et al. Novel algorithms for remote estimation of vegetation fraction[J]. Remote Sensing of Environment，2002，80(1)：76－87.
[39] MAO W，WANG Y，WANG Y. Real-time detection of between-row weeds using machine vision[C]//Proceedings of the 2003 ASAE Annual Meeting，2003.
[40] HAGUE T，TILLETT N D，WHEELER H. Automated crop and weed monitoring in widely spaced cereals[J]. Precis. Agric.，2006，7(1)：21－32.
[41] SABERIOON M M，AMIN M S M，ANUAR A R，et al. Assessment of rice leaf chlorophyll content using visible bands at different growth stages at both the leaf and canopy scale[J]. Int. J. Appl Earth. Obs. Geoinf.，2014，32(1)：35－45.
[42] GUIJARRO M，PAJARES G，RIOMOROS I，et al. Automatic segmentation of relevant textures in agricultural images[J]. Computer and Electronic in Agriculture，2011，75(1)：75－83.
[43] GAMON J A，SURFUS J S. Assessing leaf pigment content and activity with a reflectometer[J]. New Phytol，1999，143(1)：105－117.
[44] BENDIG J，YU K，AASEN H，et al. Combining UAV-based plant height from crop surface models，visible，and near infrared vegetation indices for biomass monitoring in barley[J]. Int. J. Appl. Earth. Obs. Geoinf.，2015，39(1)：79－87.
[45] HUETE A，DIDAN K，MIURA T，et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. Remote Sensing of Environment，2002，83(2)：195－213.
[46] 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.
[47] RAMOELO A，SKIDMORE A K，CHO M A，et al. Regional estimation of savanna grass nitrogen using the red-edge band of the spaceborne RapidEye sensor[J]. Int. J. Appl. Earth. Obs. Geoinf.，2012，19(1)：151－162.
[48] PORTZ G，MOLIN J P，JASPER J. Active crop sensor to detect variability of nitrogen supply and biomass on sugarcane fields[J]. Precision Agriculture，2012，13(1)：33－44.
[49] QI J，CHEHBOUNI A，HUETE A R，et al. A modified soil adjusted vegetation index[J]. Remote Sensing of Environment，1994，48(2)：119－126.
[50] GENEVIÈVE R，MICHAEL S，FRÉDÉRIC B. Optimization of soil-adjusted vegetation indices[J]. Remote Sensing of

Environment, 1996, 55(2): 95 - 107.
[51] 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.
[52] MYNENI R, WILLIAMS D. On the relationship between FAPAR and NDVI[J]. Remote Sensing of Environment, 1994, 49(3): 200 - 211.
[53] CHEN J M. Evaluation of vegetation indices and a modified simple ratio for boreal applications[J]. Can. J. Remote. Sens., 1996, 22(3): 229 - 242.
[54] 于海洋, 谢赛飞, 郭灵辉, 等. 融合光谱和空间特征的土壤重金属含量极端随机树估算[J]. 农业机械学报, 2022, 53(8): 231 - 239.
YU Haiyang, XIE Saifei, GUO Linghui, et al. Extremely randomized trees estimation of soil heavy metal content by fusing spectra and spatial features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 231 - 239. (in Chinese)
[55] MEIVEL S, MAHESWARI S. Standard agricultural drone data analytics using KNN algorithm[J]. Test Eng. Manag., 2020, 82(1): 206 - 215.
[56] 陈宇, 路阳, 蔡娣, 等. 基于 SPSO + SVM 的水稻叶部病害识别方法研究[J]. 上海农业学报, 2021, 37(6): 136 - 142.
CHEN Yu, LU Yang, CAI Di, et al. Study on recognition method of rice leaf diseases based on SPSO + SVM[J]. Acta Agriculturae Shanghai, 2021, 37(6): 136 - 142. (in Chinese)
[57] 肖通. 基于 GBDT 算法的玉米病害识别研究[D]. 娄底: 湖南人文科技学院, 2019.
XIAO Tong. Research on corn disease identification based on GBDT algorithm[D]. Loudi: Hunan University of Humanities Science and Technology, 2019. (in Chinese)
[58] SABROL H, KUMAR S. Intensity based feature extraction for tomato plant disease recognition by classification using decision tree[J]. International Journal of Computer Science and Information Security, 2016, 14(9): 622 - 627.
[59] RAY S. A quick review of machine learning algorithms[C]// Proceedings of the 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon), 2019.
[60] SHAO G, HAN W, ZHANG H, et al. Mapping maize crop coefficient Kc using random forest algorithm based on leaf area index and UAV-based multispectral vegetation indices[J]. Agric Water Manag, 2021, 252(1): e106906.
[61] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]// Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining, 2016.
[62] ZHANG X, DENG T, JIA G. Nuclear spin-spin coupling constants prediction based on XGBoost and LightGBM algorithms[J]. Mol. Phys., 2019, 118(14): e1696478.
[63] BAUMGARDNER M F, SILVA L F, BIEHL L L, et al. Reflectance properties of soils[M]. Advances in Agronomy. Elsevier, 1986: 1 - 44.
[64] HUETE A. Soil influences in remotely sensed vegetation-canopy spectral[J]. Theory and Applications of Optical Remote Sensing, 1989, 76(1): 107 - 141.
[65] 常佳迎, 刘树森, 石洁, 等. 海南三亚和黄淮海地区玉米小斑病菌致病性及遗传多样性分析[J]. 中国农业科学, 2020, 53(6): 1154 - 1165.
CHANG Jiaying, LIU Shusen, SHI Jie, et al. Pathogenicity and genetic diversity of bipolaria maydis in Sanya, Hainan and Huang - Huai - Hai Region[J]. Scientia Agricultura Sinica, 2020, 53(6): 1154 - 1165. (in Chinese)
[66] 刘焱琨. 黄淮玉米新品种对六种主要病害的抗性鉴定与评价[D]. 郑州: 河南农业大学, 2021.
LIU Yankun. Identification and evaluation of resistance of new maize varieties to six main diseases in Huang - Huai Region[D]. Zhengzhou: Henan Agricultural University, 2021. (in Chinese)
[67] 王利民, 刘佳, 邵杰, 等. 基于高光谱的春玉米大斑病害遥感监测指数选择[J]. 农业工程学报, 2017, 33(5): 170 - 177.
WANG Limin, LIU Jia, SHAO Jie, et al. Remote sensing index selection of leaf blight disease in spring maize based on hyperspectral data[J]. Transactions of the CSAE, 2017, 33(5): 170 - 177. (in Chinese)
[68] 贺佳, 王来刚, 郭燕, 等. 基于无人机多光谱遥感的玉米 LAI 估算研究[J]. 农业大数据学报, 2021, 3(4): 20 - 28.
HE Jia, WANG Laigang, GUO Yan, et al. Estimating the leaf area index of maize based on unmanned aerial vehicle multispectral remote sensing[J]. Journal of Agricultural Big Data, 2021, 3(4): 20 - 28. (in Chinese)
[69] 张宏鸣, 侯贵河, 孙志同, 等. 基于 XGBoost - Shapley 的玉米不同生育期 LAI 遥感估算[J]. 农业机械学报, 2022, 53(7): 208 - 216, 225.
ZHANG Hongming, HOU Guihe, SUN Zhitong, et al. Remote sensing estimation of maize leaf area index at different growth periods based on XGBoost - Shapley algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 208 - 216, 225. (in Chinese)