doi:10.6041/j.issn.1000-1298.2026.23.004

基于波段融合指数的小麦条锈病检测方法与系统研究

王慧婷[1]　陈旭亮[2]　王思沂[2]　仇瑞承[1]　李　寒[2]　张　漫[2]

(1. 中国农业大学信息与电气工程学院, 北京 100083;
2. 中国农业大学智慧农业系统集成研究教育部重点实验室, 北京 100083)

摘要: 小麦条锈病潜伏期症状隐蔽,传统诊断方法仅能在病症显现后识别,易错失最佳防控时机并导致小麦大幅减产。针对上述问题,本研究聚焦田间小麦条锈病潜伏期快速检测的实际需求,对自主研发的便携式病害检测设备进行迭代优化与升级。对田间原位采集的小麦条锈病光谱数据进行预处理与数据集划分,构建 6 种经典分类模型,结合四波段组合与波段融合指数构建增强特征。验证结果表明,四波段增强特征可显著提升模型识别性能,其中 MLP 与 CatBoost 模型综合表现最优,整体识别准确率最高可达 96.53%。将综合性能最优的四波段增强型 MLP 模型与全波段 MLP 模型转换为 RKNN 模型,并部署于优化后的便携式检测设备,测试结果显示,四波段增强型模型的推理效率显著高于全波段模型,且硬件资源占用更为经济,可满足小麦条锈病田间原位快速检测的实际需求,为小麦条锈病潜伏期诊断提供了一种快速、精准的技术解决方案。

关键词: 小麦条锈病; 病害检测设备; 实时检测; 光谱成像技术; 波段融合指数

中图分类号: S25　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)23-0047-10　　**OSID**:

Wheat Stripe Rust Detection Method and System Based on Band Fusion Index

Wang Huiting[1]　Chen Xuliang[2]　Wang Siyi[2]　Qiu Ruicheng[1]　Li Han[2]　Zhang Man[2]

(1. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Key Laboratory of Smart Agriculture Systems Integration*, *Ministry of Education*, *China Agricultural University*, *Beijing* 100083, *China*)

Abstract: The symptoms of wheat stripe rust during the latent period are concealed, and traditional diagnostic methods can only identify the disease after the symptoms appear, which easily leads to missing the optimal prevention and control period and a significant reduction in wheat yield. To address the above problems, it focused on the practical demand for rapid detection of wheat stripe rust during the latent period in the field, and carried out iterative optimization and upgrading of the independently developed portable disease detection device. In terms of data analysis, the wheat stripe rust spectral data collected in situ in the field were preprocessed and divided into datasets, six classic classification models were constructed, and enhanced features were built by combining four-band combinations and band fusion indices. The verification results showed that the four-band enhanced features can significantly improve the model recognition performance, among which the MLP and CatBoost models had the best comprehensive performance, with the highest overall recognition accuracy reaching 96.53%. The four-band enhanced MLP model and the full-band MLP model with the optimal comprehensive performance were converted into RKNN models and deployed on the optimized portable detection device. The test results showed that the inference efficiency of the four-band enhanced model was significantly higher than that of the full-band model, and it occupied more economical hardware resources, which can meet the practical demand for rapid in-situ detection of wheat stripe rust in the field and provide a fast and accurate technical solution for the diagnosis of wheat stripe rust during the latent period.

Key words: wheat stripe rust; disease detection device; real-time detection; spectral imaging technology; band fusion index

收稿日期: 2026-03-27　修回日期: 2026-04-01

基金项目: 国家重点研发计划项目(2022YFD200150101)和中国农业大学 2115 人才工程项目

作者简介: 王慧婷(2000—),女,硕士生,主要从事便携式作物长势监测设备研发及检测方法研究,E-mail: wanghuiting@cau.edu.cn

通信作者: 张漫(1975—),女,教授,博士,主要从事智慧农业、农业机械导航定位和农业物联网等研究,E-mail: cauzm@cau.edu.cn

0 引言

小麦作为全球核心粮食作物，其产量与品质直接关系国家粮食安全及农业经济发展，而条锈病作为小麦生长周期中危害最突出的病害，不仅会通过侵染植株导致产量下降，还因孢子易远距离传播、易暴发蔓延，使得实现其精准高效识别成为农业科研与生产实践的关键需求[1-4]。传统检测依赖人工目视或专家经验，存在效率低、主观性强、准确性不足等缺陷，难以满足现代植物保护早期预警需求[5]。尤其在潜伏期，病原已侵入但未显症，此阶段的有效识别可为病害预测与精准防控提供关键依据。发展快速客观的智能识别方法，可及时干预病害发展、减少化学农药施用、降低环境污染、保障农产品质量安全与人类健康[6-7]；结合田间便携式检测装备，对实现病害早期诊断具有重要应用价值。

近年来，遥感技术尤其是光谱成像技术迅猛发展，该技术具备快速、无创的信息获取优势，能够捕捉植物生理与健康状态的细微变化，这些变化往往难以通过肉眼或传统多光谱成像技术识别，因此被广泛应用于作物病害检测领域[8-12]。尽管这些方法均具备较高检测精度，但所用光谱检测设备普遍存在体积庞大、成本高昂的问题，且数据分析需依赖外置计算机，难以满足田间实时监测的需求[13]。

随着农业现场检测对装置便携性需求的提升及小型化光谱检测技术的迅猛发展，便携式作物表型监测仪器已在农业领域获得广泛应用。郭文川等[14]基于多光谱技术设计了一款可更换探头的手持式多果品内部品质无损检测仪，通过探头更换可实现多种果品内部品质的快速无损检测，但该设备存在光谱波段偏少的局限；彭望等[15]开发了基于近红外光谱的便携式油菜籽内部品质检测装置，其集成微型光谱仪，仅具备点光谱测量功能，缺乏成像功能；Wang 等[16]推出了一款名为 LeafSpec 的手持式低成本高光谱成像设备，其硬件组成包括推扫式高光谱相机、带位置编码系统的叶片扫描仪、高强度均匀光源灯箱及 ARM 架构微控制器。该设备操作简便，沿叶片从基部滑动至顶端即可获取全叶片平滑清晰的高光谱图像，但仍存在成本偏高的问题。

综上，研发一套可实现小麦条锈病潜伏期现场无损检测的便携式方法及系统，对实现病害早期预警与精准防控具有重要现实意义，亦是当前农业植保领域的迫切需求[17-18]。为此，本研究拟开发一款便携式小麦条锈病潜伏期检测系统。优化升级自主研发的便携式检测设备，解决其实际应用中存在的操作便捷性不足、定位可靠性欠佳及图像数据准确性偏低等问题；对比不同波段融合指数和算法模型在小麦条锈病检测与分类任务中的性能差异，进行数据分析与模型优化，并进行部署；进一步对系统性能进行测试，以验证优化后系统在田间场景下的检测精度与运行稳定性。

1 材料与方法

1.1 硬件系统改进与结构特点

研究团队自主研发的便携式检测设备在实际田间应用中暴露出以下问题：屏幕固定不可翻折，导致在太阳光照射下屏幕内容不易辨识；未配备 WiFi 模块，数据传输便捷性不足；缺乏电量显示功能，野外实验不便掌握设备续航状态；内置的 4G 模块 GNSS 性能较弱，定位精度与稳定性欠佳；RGB 成像存在偏白、色彩失真现象，难以保障图像数据的准确性。针对上述问题，本研究进行了改进升级，实现了新一代便携式作物长势监测设备的研发。

新一代传感器整体架构如图 1 所示，仍采用模块化设计以保证系统的可扩展性与维护性。其中，RGB 相机模块升级，通过 USB 2.0 接口与主控模块实现稳定数据传输；显示模块采用可翻转 MIPI 显示屏（最大翻转至垂直状态），提升田间人机交互体验；单独集成 GNSS 模块（通过 TTL 接口与主控连接），确保复杂大田环境下定位精准快速；增设 WiFi 模块（通过 PCIe 接口与主控连接），为后续数据传输及远程管理提供支持。

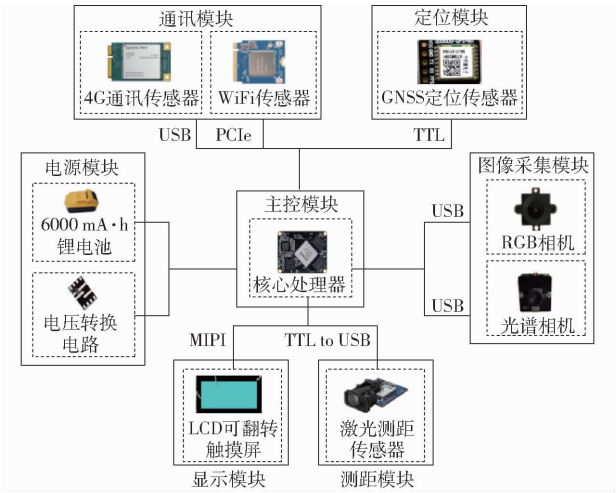

图 1 系统总体设计架构图

Fig. 1 Overall design architecture diagram of system

设备实物升级变化如图 2 所示，整体设计仍遵循紧凑型与轻量化原则，整机尺寸为 140 mm × 144 mm × 310 mm，质量仅 1.8 kg，符合人体工程学手持要求，便于长时间田间作业。可旋转触摸屏，操作角度可调减少自然光干扰；模块化架构在保证功能完备性的同时有效提升了设备的便携性，为作物

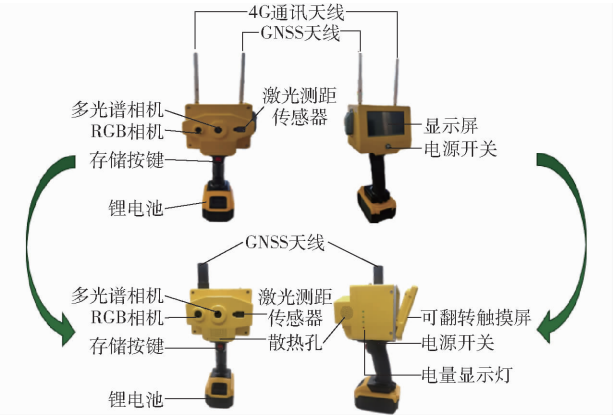

图 2　便携式检测设备实物升级变化图

Fig. 2　Physical upgrade and transformation diagram of portable detection device

病害实时检测与长势监测提供了可靠的技术方案。

表 1 列出了升级后便携式检测装置的核心模块配置，针对上一代装置实际应用中出现的问题，对相关传感器进行了迭代更换，有效提升了装置的田间操作便捷性与使用体验。此外，装置电源系统采用模块化设计方案，搭载 6 000 mA·h 可拆卸锂电池组，并集成高效电压转换电路，可拆卸的电池设计支持快速换电操作，能够保障装置在田间作业过程中实现不间断运行。

1.2　软件设计与实现

为满足便携式作物病害检测装置的田间实际应用需求，本研究设计并实现了功能完善的软件操作界面，整体软件功能架构图如图 3 所示，小麦条锈病

表 1　新一代便携式检测设备核心模块

Tab. 1　Introduction to core module of new generation portable detection device

传感器名称	型号规格	主要性能
多光谱相机	CM020A 型快照式成像光谱相机 （吉林求是光谱数据科技有限公司）	采集波长范围：400 ~ 950 nm 光谱分辨率：20 nm（ 27 个波段） 图像分辨率：1 600 像素 ×1 200 像素
可见光相机	DECXIN－8M－2614V1 型相机 （深圳市德创信影像科技有限公司）	最大分辨率：3 840 像素 ×2 160 像素 输出图像格式：MJPEG/YUV2 信噪比：30 dB
测距传感器	L1 型单点激光测距传感器 （深圳市摩天射频技术有限公司）	系统启动时间：600 ms 通信接口：TTL UART
可翻转触摸屏	4.3 英寸触摸屏 （耀元鸿科技）	分辨率：800 像素 ×480 像素 接口类型：MIPI
4G 通讯传感器	EC20 模块 （移远通信技术股份有限公司）	供电电压：3.0 ~ 3.6 V，典型值 3.3 V
WiFi 传感器	AP6275P 通信模块 （正基科技有限公司）	最优性能区间：－10 ~ 55℃、3.2 ~ 3.6 V
GNSS 传感器	ATGM336H－5N （杭州中科微电子有限公司）	首次定位时间：32 s 连续运行电流：小于 25 mA

病害检测界面集成了图像采集、数据存储、参数控制及结果显示 4 个核心功能模块，各模块既相互独立，又通过软件总线实现数据交互与协同工作，确保不同作物长势检测的针对性与高效性，为后续条锈病精准识别与长势评估提供可靠的软件支撑。

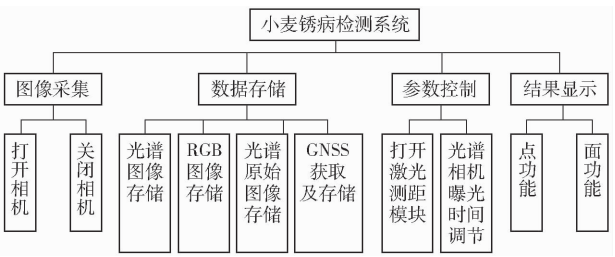

图 3　小麦条锈病检测软件功能设计架构图

Fig. 3　Functional design architecture diagram of wheat stripe rust detection software

图像采集模块同步调用可见光与光谱相机，通过精准时序控制保障拍摄同步性，规避数据偏差；数据存储模块支持检测数据与 GNSS 信息一键同步保存，借助采集时间自动命名实现数据规范化管理，提升田间采集效率；参数控制模块可调节光谱相机曝光时间以适配田间动态光照，集成激光测距功能校正拍摄距离偏差，保障数据稳定性与精度；结果显示模块融合面、点功能子模块，面功能实现病害区域显示、病害率计算及结果云端上传，点功能获取叶片光谱反射率曲线并完成精准诊断，二者协同实现病害宏观至微观全方位检测。各模块通过软件总线实现高效数据交互与协同联动，为小麦条锈病精准识别、长势评估及防控决策制定提供可靠软件支撑。

1.3　实验设计

2024 年 4 月 21 日至 5 月 12 日、2025 年 6 月 6 日至 6 月 8 日，在山东省烟台市（37°32′14″N，

121°23′36″E,图 4)开展小麦条锈病田间连续观测实验,供试品种为烟农 1212、烟农 38、烟农 999。小麦孕穗期采用喷雾法人工接种条锈病,实验设接种区与健康对照区,选取接种区 12 个小麦冠层、对照区 6 个健康冠层为观测对象,晴朗天气下连续监测采集数据;2024 年获取 14 d 内小麦 27 个波段光谱图像数据,2025 年开展补充实验完善光谱数据集。

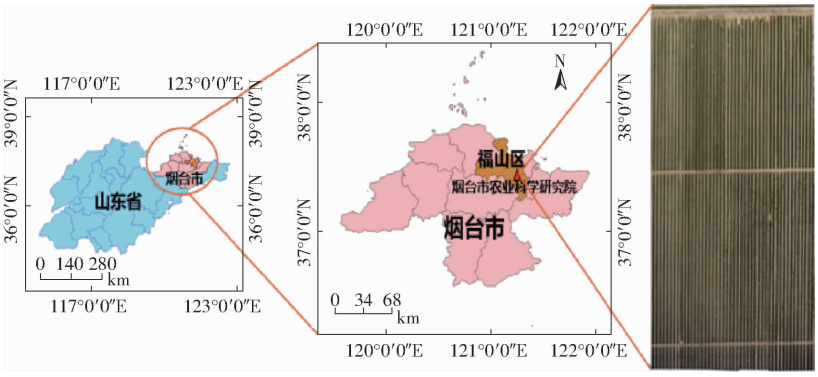

图 4 实验数据采集地点

Fig. 4 Location of experimental data collection

实验严格控制采集条件:便携式检测设备垂直向下拍摄,采集时间为晴朗午间 11:00—14:00,采集前 1 h 完成设备调试;每次采集前用测距模块校准拍摄距离,每采集 3 个冠层用 80% 反射率标准白板进行光谱校正,保持光谱相机曝光时间恒定;每个样本重复采集 2 次。14 d 监测累计获取光谱图像数据超 200 组,建模前进行点光谱数据提取。

以 9 像素 ×9 像素为提取单元,从高光谱图像中提取数据构建光谱数据集:健康样本点取自对照区叶片,潜伏期样本点取自接种后未显症但后期发病或发病过渡区域,显症样本点取自孢子堆明显区域。2024 年从 3 类样本中各提取 125 条光谱数据(共 375 条)作为测试集;2025 年各提取 500 条(共 1 500 条)作为训练集,训练集与测试集比例约 8:2,为后续模型训练、优化及验证提供规范数据支撑。

1.4 小麦条锈病检测模型构建

对于采集的光谱数据,首先进行预处理,分别采用 Savitzky - Golay 平滑、跨年度标准化与标准正态变量变换(Standard normal variate, SNV),剔除原始光谱噪声、校正基线漂移并提升数据质量。其次,基于预处理后光谱数据,采用 2 种并行建模方案:一是以全波段光谱为输入,分别构建支持向量机(Support vector machine, SVM)、随机森林(Random forest, RF)、极端梯度提升(eXtreme gradient boosting, XGBoost)、轻量级梯度提升机(Light gradient boosting machine, LightGBM)、类别特征梯度提升(Categorical boosting, CatBoost)及多层感知机(Multilayer perceptron, MLP)共 6 种模型;二是在前期对比实验中,已分别对三波段、四波段、五波段组合进行遍历验证,结果表明四波段组合能够在特征信息量与模型复杂度之间取得最佳平衡,因此本研究最终选取四波段开展组合优化描述。最后基于 27 个波段开展四波段组合遍历,设计 7 种融合指数,并将其与对应波段反射率拼接为 5 维特征向量,通过 5 折交叉验证筛选最优融合指数,构建与前述一致的模型与全波段光谱模型进行对比分析。

1.4.1 数据预处理

根据所拍摄目标叶片同一时段下所存储的校正板数据,得到校正板校正后的光谱反射率数据,计算式为

$$r_i = \frac{Q_i}{Q_w} r_w \tag{1}$$

式中 r_i——最终点的反射率结果

Q_i——该点的光谱值

Q_w——所拍摄校正板的光谱值

r_w——校正板各波段对应的反射率数据

随后,采用 Savitzky - Golay(S - G)滤波平滑光谱。因训练集与测试集样本分属不同年份,光照强度、温湿度等采集环境差异造成二者光谱分布显著偏移,直接建模会大幅降低模型的跨年度泛化能力。为此设计跨年度校准策略,以训练集光谱为参考对测试集进行校正,实现数据集分布对齐,即

$$X_{\text{test}}^{\text{cal}} = \frac{X_{\text{test}} - \mu_{\text{test}}}{\sigma_{\text{test}}} \sigma_{\text{train}} + \mu_{\text{train}} \tag{2}$$

式中 $X_{\text{test}}^{\text{cal}}$——校准后的测试集光谱反射率数据

X_{test}——经过 S - G 滤波后的测试集原始光谱反射率数据

μ_{test}、σ_{test}——测试集对应波段光谱反射率的均值与标准差

μ_{train}、σ_{train}——训练集对应波段光谱反射率的均值与标准差

校准步骤如下:计算两数据集各对应波段的均

值与标准差，对测试集各波段做标准化处理，再将标准化后的测试集波段反射率乘以训练集对应波段标准差并叠加其均值，完成测试集光谱校准。最后通过 SNV 消除光谱基线漂移。

1.4.2　全波段模型建立

为系统评估光谱预处理后特征数据的分类性能，对比不同机器学习模型在小麦条锈病分类任务中的适配性，本研究构建 6 类经典分类模型，涵盖传统机器学习与深度学习基础模型，包括 SVM、RF、XGBoost、LightGBM、CatBoost 以及 MLP。所有模型均基于预处理光谱特征数据构建，统一设置随机种子（Random State 为 42）以保证实验可重复性，并结合各类模型核心特性优化关键参数：对 SVM、RF 等传统机器学习模型，重点调整正则化与模型复杂度参数；对 XGBoost、LightGBM、CatBoost 等梯度提升类模型，优化学习率、决策树数量与深度，平衡模型拟合效果与泛化能力；对 MLP 模型，调整隐藏层数量、神经元个数及激活函数。通过参数优化确保各类模型充分挖掘光谱特征与小麦条锈病发病状态的内在关联，为后续模型性能对比与最优模型筛选奠定可靠基础[7,19-20]。

1.4.3　波段融合指数增强型模型建立

基于预处理后的光谱特征，采用 7 种常见的波段融合指数计算方法，所有方法均以 4 个候选波段反射率为基础构建[21-22]；同时，从 27 个有效波段中遍历所有四波段组合方式（组合数计算数为 C_{27}^{4} = 17 550 种），针对每种四波段组合，运用上述 7 种融合指数公式（记为 TNI1—TNI7）分别计算对应的波段融合指数，具体计算公式为

$$TNI1 = \frac{R_a - R_b}{R_c + R_d} \tag{3}$$

$$TNI2 = \frac{R_c - R_b}{R_a - R_d} \tag{4}$$

$$TNI3 = \frac{R_a - R_d}{R_b + R_c} \tag{5}$$

$$TNI4 = \frac{R_c - R_d}{R_a + R_b} \tag{6}$$

$$TNI5 = (R_a - R_b)(R_c - R_d) \tag{7}$$

$$TNI6 = \frac{R_c}{R_a + R_b} - \frac{R_d}{R_a} \tag{8}$$

$$TNI7 = \frac{R_c - R_b}{R_b + R_c}\frac{R_a}{R_d} \tag{9}$$

其中 R_a、R_b、R_c、R_d 代表该四波段组合中 4 个波段的反射率（按波长升序排序）。

将各融合指数与对应四波段组合的反射率拼接，构建 5 维特征向量。为筛选最优波段融合指数，采用 5 折交叉验证（随机种子为 42），以宏平均 F1 分数为核心评价指标，对所有四波段组合及对应融合指数开展全面评估。筛选时，针对每类四波段组合的各融合公式，均构建临时分类模型（采用与正式模型一致的基础参数）并计算其交叉验证宏平均 F1 分数，选取该值最高的融合公式作为最优波段融合指数，用于后续正式模型训练，以强化模型对小麦条锈病发病特征的捕捉能力，提升模型特征表达水平与分类精度。

为全面对比不同模型分类性能，保证实验结论的可靠性、全面性与对比公平性，同步构建 SVM、RF、XGBoost、LightGBM、CatBoost、MLP 6 种机器学习模型，模型类型与全波段模型保持一致，为后续四波段增强型模型与全波段模型、各模型间的系统对比分析奠定坚实基础。

1.5　模型评价指标

本研究数据预处理及模型构建均在 PyCharm Community Edition 2023.2.5 平台完成。为客观量化各模型测试集分类性能，规避单一指标局限，选取精确率、召回率、准确率、F1 分数、科恩卡帕系数（κ）及受试者工作特征曲线下面积（AUC）S_{AUC} 为核心指标。

科恩卡帕系数 κ 的计算公式为

$$\kappa = 2\frac{p_o - p_e}{1 - p_e} \tag{10}$$

其中

$$p_o = \frac{\sum_{i=1}^{C} n_{ii}}{N} \tag{11}$$

$$p_e = \frac{\sum_{i=1}^{C} (n_{i+} n_{+i})}{N^2} \tag{12}$$

式中　p_o——预测与真实标签实际一致比例

C——类别总数

n_{ii}——第 i 类正确分类样本数

p_e——随机预测预期一致比例

n_{i+}——第 i 类的实际总样本数

n_{+i}——模型预测为第 i 类的总样本数

N——测试集总样本数量

受试者工作特征曲线下面积（S_{AUC}）的计算公式及相关衍生指标为

$$S_{AUC} = \int_0^1 N_{TPR}(N_{FPR})\,\mathrm{d}N_{FPR} \tag{13}$$

其中

$$N_{TPR} = \frac{N_{TP}}{N_{TP} + N_{FN}} \tag{14}$$

$$N_{FPR} = \frac{N_{FP}}{N_{FP} + N_{TN}} \tag{15}$$

式中　N_{TPR}——真阳性率

N_{FPR}——假阳性率
N_{TP}——真正例样本数
N_{TN}——真负例样本数
N_{FP}——假正例样本数
N_{FN}——假负例样本数

多类别任务 S_{AUC} 值采用一对一(One-versus-Rest, OvR)策略计算,取各类别 ROC 曲线下面积加权平均值(权重为类别样本占比),保障评估客观性。

精确率反映预测正类的可靠性;召回率反映实际正类的识别完整性;准确率为模型整体正确预测占比;F1 分数平衡精确率与召回率,适配类别不平衡数据集;κ 系数校正偶然一致性,适配类别分布不均任务;S_{AUC} 量化类别区分能力,越接近 1 则模型判别与抗干扰能力越强[23-25]。

2 结果与讨论

2.1 模型性能分析

2.1.1 小麦条锈病光谱数据分析

经校正板校正后的小麦条锈病光谱数据中,健康、潜伏期发病及显症发病 3 类样本的平均光谱反射率曲线如图 5 所示。由图 5 可见,小麦植株感染条锈病后,不同波段的光谱反射率呈规律性变化,且变化趋势与病害严重程度显著相关:在 400 ~ 700 nm 可见光波段,随病害程度加剧,叶片叶绿素合成受阻、降解加速,其对蓝光和红光的吸收能力显著减弱,导致该波段光谱反射率明显升高;在 700 ~ 950 nm 近红外波段,条锈病侵染破坏叶片细胞结构,使叶肉组织光散射效应大幅减弱,进而造成该波段光谱反射率显著降低。

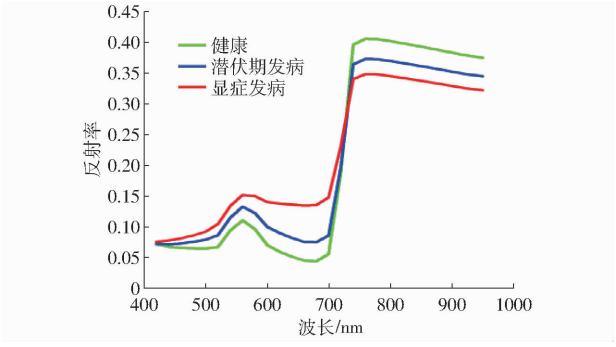

图 5 健康、潜伏期发病、显症发病样本平均光谱反射率曲线

Fig. 5 Average spectral reflectance curves of healthy points, latent period points, and symptomatic points

上述可见光与近红外波段的规律性光谱变化,构成了区分小麦条锈病感染程度的核心光谱指标,为基于高光谱技术开展小麦条锈病快速无损诊断提供了理论依据与数据支撑。此外,潜伏期发病与健康样本在可见光波段的光谱差异微弱,增加了早期诊断难度。而潜伏期样本在近红外波段的反射率已呈显著降低特征,这一特异性光谱变化为小麦条锈病潜伏阶段的监测与早期诊断提供了重要光谱依据。

2.1.2 全波段模型性能分析

表 2 展示了输入全波段的模型性能 3 类样本(1 类:健康点,2 类:潜伏期发病点,3 类:显症发病点)的判别呈现显著规律性。由表 2 可知,在直接采用全波段原始光谱作为输入特征时,6 种机器学习模型对小麦条锈病健康、潜伏期发病与显症发病 3 类样本的识别性能整体未达到理想水平,且不同模型间存在明显差异。在总体评价指标方面,准确率介于 60.00% ~ 80.27%,宏平均 F1 分数为 0.587 2 ~ 0.792 2,Kappa 系数为 0.400 0 ~ 0.704 0,S_{AUC} 为 0.854 7 ~ 0.933 4,表明仅依靠全波段光谱难以实现稳定、可靠的病害分级识别。从类别判别结果来看,各模型对健康样本与显症发病样本的召回率与精确率相对较高,而对潜伏期发病样本的识别效果普遍较差,存在大量误判为健康或显症发病样本的现象,说明全波段光谱中包含大量冗余信息与噪声干扰,对早期、弱信号的病害特征表达能力不足。

整体而言,全波段输入虽保留了光谱全貌,但维度冗余、特征不聚焦,导致模型分类精度有限、泛化能力较弱,难以满足小麦条锈病高精度、早期识别的实际需求,也印证了开展波段优选与特征融合以提升病害识别性能的必要性与合理性。

2.1.3 波段融合指数增强型模型性能分析

综合波段融合指数筛选与模型构建结果表明,通过 5 折交叉验证对不同四波段组合及 7 种波段融合指数进行定量评估,可有效筛选出对小麦条锈病光谱特征最敏感的最优波段融合指数。实验结果显示,由 460、660、740、880 nm 构成的 TNI6 波段融合指数宏平均 F1 分数最优,将其与 4 个优选波段反射率拼接构建的 5 维特征向量,可显著增强模型对病害关键光谱特征的提取能力,提升特征表达与分类精度。在此基础上,本研究构建了与全波段模型完全一致的 SVM、RF、XGBoost、LightGBM、CatBoost 及 MLP 共 6 种机器学习模型,保证了对比实验的公平性与严谨性。

由表 3 可知,四波段增强特征输入下,各模型对小麦条锈病健康、潜伏期发病及显症发病样本均表现出优异识别性能,整体分类精度较全波段输入显著提升。所有模型均实现高精度分类,准确率为 79.20% ~ 96.53%,F1 分数为 0.792 4 ~ 0.965 1,

表 2　全波段所建立 6 种机器学习分类模型的性能

Tab. 2　Performance of six machine learning classification models established in full band

模型	真实类别	预测样本数量			召回率/%	精确率/%	准确率/%	F1 分数	Kappa 系数	S_{AUC}
		1	2	3						
SVM	1	93	32	0	74.40	79.49	—	0.768 6	—	—
	2	24	40	61	32.00	54.79	—	0.404 0	—	—
	3	0	1	124	99.20	67.03	—	0.800 0	—	—
	总计	117	73	185	—	—	68.53	0.657 5	0.528 0	0.854 7
RF	1	48	77	0	38.40	92.31	—	0.542 9	—	—
	2	4	61	60	48.80	41.50	—	0.448 5	—	—
	3	0	9	116	92.80	65.91	—	0.770 6	—	—
	总计	52	147	176	—	—	60.00	0.587 2	0.400 0	0.854 8
XGBoost	1	73	52	0	58.40	89.02	—	0.704 8	—	—
	2	9	66	50	52.80	51.97	—	0.523 0	—	—
	3	0	9	116	92.80	69.88	—	0.797 3	—	—
	总计	82	127	166	—	—	68.00	0.675 0	0.520 0	0.878 9
LightGBM	1	124	1	0	99.20	91.85	—	0.953 7	—	—
	2	11	66	48	52.80	81.48	—	0.640 5	—	—
	3	0	14	111	88.80	69.81	—	0.781 8	—	—
	总计	135	81	159	—	—	80.27	0.792 2	0.704 0	0.933 4
CatBoost	1	119	6	0	95.20	92.97	—	0.940 1	—	—
	2	9	68	48	54.40	78.16	—	0.641 9	—	—
	3	0	13	112	89.60	70.00	—	0.785 9	—	—
	总计	125	87	160	—	—	79.73	0.789 4	0.696 0	0.900 2
MLP	1	113	12	0	90.40	86.92	—	0.886 0	—	—
	2	17	96	12	76.80	56.14	—	0.648 4	—	—
	3	0	63	62	49.60	83.78	—	0.623 0	—	—
	总计	130	171	74	—	—	72.27	0.719 3	0.584 0	0.890 2

注：1、2、3 分别表示健康、潜伏期发病和显症发病样本，“—”表示该指标在此层级无计算意义，下同。

Kappa 系数为 0.688 0 ~ 0.948 0，S_{AUC} 为 0.955 8 ~ 0.995 4，表明四波段增强特征可有效聚焦病害敏感信息，剔除冗余信号，具有较强的判别能力与可靠性。除 SVM 外，其余 5 种模型性能稳定优异，其中 MLP 与 CatBoost 综合表现最优，分别得益于对非线性特征的强拟合能力及对特征冗余与类别不平衡样本的良好适应性。

从类别识别结果来看，除 SVM 外，各模型对 3 类样本均实现精准识别，其中潜伏期发病样本的召回率与精确率均高于 87%，显著优于全波段特征，有效缓解了早期病害易误判的问题；对健康与显症发病样本的识别精度接近 100%，体现出四波段增强特征对不同发病阶段光谱差异的优异表征能力。

综上，经波段优选与融合构建的四波段增强特征，可有效剔除冗余信息与噪声干扰，显著提升模型特征表达能力与分类精度，实现健康、潜伏期及显症发病样本的可靠区分，满足小麦条锈病早期识别与分级诊断需求，同时降低特征维度、减轻过拟合风险，为构建轻量化、高精度、强泛化的病害早期识别模型提供核心支撑，也为同类作物病害光谱识别研究提供参考。

2.2　系统性能测试

2.2.1　部署后准确率性能测试

为实现小麦条锈病田间原位快速检测，本研究将性能最优的四波段增强型 MLP 模型与全波段 MLP 模型均转换为 RKNN 格式，并部署至便携式检测设备。采用 2024 年的 375 条光谱数据作为测试集，对比模型部署前后的分类精度，结果如表 4 所示。

四波段增强型 MLP 模型部署后总体准确率为 95.47%，较原始模型（96.53%）仅下降 1.06 个百分点，在 RKNN 量化与边缘部署后仍保持稳定高效的分类性能。全波段 MLP 模型部署后准确率为 68.80%，较原始模型（72.27%）下降 3.47 个百分点，精度损失为前者的 3.27 倍。差异主要源于特征维度与量化适应性：四波段增强模型仅为 5 维特征，冗余信息少、特征判别性强，量化损失可控；全波段模型含 27 维原始光谱特征，冗余信息多，高维特征在量化中损失更为显著。结果表明，波段融合指数增强型 MLP 模型分类性能优异、部署适应性强、精度损失小，更适用于便携式设备的田间实际应用。

表 3 四波段增强特征模型所建立 6 种机器学习分类模型的性能

Tab. 3 Performance of six machine learning classification models established by four-band enhanced feature model

模型	真实类别	预测样本数量			召回率/%	精确率/%	准确率/%	F1 分数	Kappa 系数	S_{AUC}
		1	2	3						
SVM	1	94	31	0	75.20	72.31	—	0.736 9	—	—
	2	36	85	4	68.00	69.11	—	0.685 5	—	—
	3	0	7	118	94.40	96.72	—	0.955 4	—	—
	总计	130	123	122	—	—	79.20	0.792 4	0.688 0	0.955 8
RF	1	121	4	0	97.00	97.00	—	0.970 0	—	—
	2	4	114	7	91.20	95.00	—	0.929 5	—	—
	3	0	2	123	98.40	94.60	—	0.964 8	—	—
	总计	125	120	130	—	—	95.47	0.954 8	0.932 0	0.991 1
XGBoost	1	121	4	0	96.80	94.53	—	0.956 5	—	—
	2	7	109	9	87.20	95.61	—	0.911 9	—	—
	3	0	1	124	99.20	93.23	—	0.960 9	—	—
	总计	128	114	133	—	—	94.40	0.943 3	0.916 0	0.988 6
LightGBM	1	121	4	0	96.80	94.53	—	0.956 5	—	—
	2	7	110	8	88.00	95.65	—	0.916 4	—	—
	3	0	1	124	99.20	93.94	—	0.964 6	—	—
	总计	128	115	132	—	—	94.67	0.946 1	0.920 0	0.990 5
CatBoost	1	122	3	0	97.60	97.60	—	0.976 0	—	—
	2	3	115	7	92.00	96.64	—	0.942 5	—	—
	3	0	1	124	99.20	94.66	—	0.968 7	—	—
	总计	125	119	131	—	—	96.27	0.962 5	0.944 0	0.995 4
MLP	1	121	4	0	96.80	96.80	—	0.968 0	—	—
	2	4	116	5	92.80	96.67	—	0.946 8	—	—
	3	0	0	125	100	96.15	—	0.980 4	—	—
	总计	125	120	130	—	—	96.53	0.965 1	0.948 0	0.994 2

表 4 模型部署前后总体准确率对比

Tab. 4 Comparison of overall accuracy before and after model deployment

模型	原始总体准确率/%	部署后总体准确率/%	准确率损失/百分点
四波段融合指数增强型 MLP 模型	96.53	95.47	1.06
全波段 MLP 模型	72.27	68.80	3.47

2.2.2 推理速度及资源占用性能测试

除分类精度外,推理效率、硬件资源占用与模型存储占用量是决定模型能否适配便携式田间检测设备的关键指标。基于便携式检测设备,以 375 条测试样本为基准,对四波段增强型 MLP 模型与全波段 MLP 模型的非精度性能进行对比测试,结果如表 5 所示。

由表 5 可知,推理效率方面,四波段模型优势显著。处理 375 条样本总耗时仅 0.149 3 s,平均推理延迟 0.398 ms,吞吐量达 2 511.5 f/s。全波段模型总耗时 0.281 0 s,平均推理延迟 0.749 ms,为四波段模型的 1.88 倍,吞吐量仅 1 334.4 f/s,较四波段模型下降 46.9%。差异主要源于输入维度不同:四波段模型输入仅 5 维,计算量小;全波段模型为 27 维,冗余特征多、计算开销大。硬件资源占用方面,两款模型存储占用量均为 0.05 MB,存储占用极低;四波段模型 CPU 使用率为 14.2%,较全波段模型(15.0%)低 5.33%,资源利用更高效。

综上,四波段融合指数增强型 MLP 模型推理延迟低、吞吐量大,可满足田间实时检测需求,且资源占用更经济,完全适配便携式检测设备。全波段模

表 5 模型部署前后性能比较

Tab. 5 Comparison of model performance before and after model deployment

模型	总体推理时间/s	平均推理时间/ms	吞吐量/($f \cdot s^{-1}$)	模型存储占用量/MB	CPU 使用率/%	输入维度
四波段融合指数增强型 MLP 模型	0.149 3	0.398 2	2 511.5	0.05	14.2	5
全波段 MLP 模型	0.281 0	0.749 4	1 334.4	0.05	15.0	27
变化率/%	-46.87	-46.86	+88.21	0	-5.33	-81.48

型因维度高、计算量大，推理效率偏低，难以满足实时性要求。

2.3 讨论

针对现有便携式病害检测设备的应用不足，本研究优化设计并开发了新一代便携式检测设备，升级 RGB 相机模块、采用可翻转式 MIPI 显示屏提升操作便捷性，集成 GNSS 与 WiFi 模块，为田间数据传输及远程管理提供硬件支撑。

通过田间原位实验获取小麦条锈病不同发病阶段光谱数据，验证了设备的稳定性与实用性。以 2025 年数据为训练集、2024 年数据为验证集，对原始光谱经 Savitzky－Golay 平滑、跨年度标准化及 SNV 变换预处理后，构建 6 种经典机器学习模型；基于 27 个有效波段遍历四波段组合，设计 7 种融合指数并与对应波段反射率拼接为 5 维特征向量，经 5 折交叉验证筛选最优融合指数，同步构建同类模型保障对比公平性。结果表明，四波段增强特征可显著提升模型分类精度，各模型准确率为 79.20% ~ 96.53%，宏平均 F1 分数为 0.792 4 ~ 0.965 1，Kappa 系数为 0.688 0 ~ 0.948 0，S_{AUC}为 0.955 8 ~ 0.995 4，其中 MLP 与 CatBoost 模型表现最优。

将最优四波段增强型 MLP 模型与全波段 MLP 模型转换为 RKNN 格式，部署于 RK3588 平台便携式设备，四波段模型推理效率与资源适配性显著优于全波段模型，完全满足田间原位检测需求。

本研究模型目前仅适用于特定病害检测，存在应用局限；未来将通过优化模型结构、扩充多作物多病害数据集、改进特征策略，提升模型泛化能力，实现多作物多病害一体化智能识别监测，为作物病害精准防控提供技术支撑。

3 结论

（1）针对田间小麦条锈病潜伏期快速检测需求，本研究迭代升级上一代便携式病害检测设备。通过田间原位采集小麦条锈病不同发病阶段光谱数据，经预处理后构建 6 种分类模型，结合四波段组合与波段融合指数构建增强特征，验证表明四波段增强特征可显著提升识别性能，其中 MLP 与 CatBoost 模型表现最优，准确率最高可达 96.53%。将最优四波段增强型 MLP 模型与全波段 MLP 模型转换为 RKNN 格式，部署于 RK3588 便携式检测设备，四波段模型平均推理延迟 0.398 ms、吞吐量 2 511.5 f/s、CPU 使用率 14.2%，对比全波段模型，推理效率更高、资源占用更经济，完全适配田间原位检测需求。

（2）本文研发的检测系统为小麦条锈病实时原位检测提供了高效技术方案，契合智慧农业发展趋势，可降低人工巡检成本，应用价值良好。未来将扩大数据集规模，纳入多作物多病害样本及相关性能参数，优化模型算法与设备硬件，推动系统田间规模化应用，为智慧农业病虫害绿色防控提供技术支撑。

参 考 文 献

[1] 潘爱霞. 山东地区小麦条锈病发生机制及其防治措施的综合探讨[J]. 种子世界，2025(9)：99－101.
Pan Aixia. Comprehensive discussion on the occurrence mechanism and prevention measures of wheat stripe rust in Shandong region[J]. Seed World, 2025(9): 99－101. (in Chinese)

[2] 薛亮亮，冯芳，吉汉语，等. 小麦条锈病防治措施及防治技术创新性研究进展[J]. 粮食问题研究，2025(4)：36－38.
Xue Liangliang, Feng Fang, Ji Hanyu, et al. Research progress on prevention measures and technological innovation of wheat stripe rust[J]. Grain Issues Research, 2025(4): 36－38. (in Chinese)

[3] Guo A, Huang W, Qian B, et al. Improved early detection of wheat stripe rust through integration pigments and pigment-related spectral indices quantified from UAV hyperspectral imagery[J]. International Journal of Applied Earth Observation and Geoinformation, 2024, 135: 104281.

[4] Jing X, Du K, Duan W, et al. Quantifying the effects of stripe rust disease on wheat canopy spectrum based on eliminating non-physiological stresses[J]. Crop Journal, 2022, 10(5): 1284－1291.

[5] Patel R, Mitra B, Vinchurkar M, et al. Plant pathogenicity and associated/related detection systems. A review[J]. Talanta, 2023, 251: 123808.

[6] Srivastava M, Sisaudia V, Meena J. A review on internet of things and artificial intelligence based plant disease detection: taxonomy, issues and challenges[J/OL]. Journal of Plant Diseases and Protection, 2025－11－11. https://doi.org/10.1007/s41348－025－01184－0.

[7] Thakur P S, Khanna P, Sheoreey T, et al. Trends in vision-based machine learning techniques for plant disease identification: a systematic review[J]. Expert Systems with Applications, 2022, 208: 118117.

[8] Bai Y, Nie C, Yu X, et al. Comprehensive analysis of hyperspectral features for monitoring canopy maize leaf spot disease[J]. Computers and Electronics in Agriculture, 2024, 225: 109350.

[9] Tian L, Xue B, Wang Z, et al. Spectroscopic detection of rice leaf blast infection from asymptomatic to mild stages with integrated machine learning and feature selection[J]. Remote Sensing of Environment, 2021, 257: 112350.

[10] Parikshith H, Rajath S M N, Kumar S P P. Leaf disease detection using image processing and artificial intelligence: a survey

[C]// Smys S, Tavares J, Balas V E, et al. Computational Vision and Bio-Inspired Computing: 1108. Cham: Springer, 2020: 304 – 311.

[11] Zhang D Y, Chen G, Yin X, et al. Integrating spectral and image data to detect Fusarium head blight of wheat[J]. Computers and Electronics in Agriculture, 2020, 175: 105588.

[12] Xue B, Tian L, Wang Z, et al. Quantification of rice spikelet rot disease severity at organ scale with proximal imaging spectroscopy[J]. Precision Agriculture, 2023, 24(3): 1049 – 1071.

[13] Yang B, Guo W, Huang X, et al. A portable, low-cost and sensor-based detector on sweetness and firmness grades of kiwifruit [J]. Computers and Electronics in Agriculture, 2020, 179: 105831.

[14] 郭文川, 纪同奎, 张宗逸, 等. 可更换探头的手持式多果品内部品质无损检测仪研究[J]. 农业机械学报, 2023, 54(2): 403 – 409.
Guo Wenchuan, Ji Tongkui, Zhang Zongyi, et al. Research on a handheld non-destructive detector for internal quality of multiple fruits with replaceable probes[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 403 – 409. (in Chinese)

[15] 彭望,王前,廖庆喜,等. 基于近红外光谱的便携式油菜籽品质检测装置研制[J]. 农业工程学报,2024,40(18):13 – 22.
Peng Wang, Wang Qian, Liao Qingxi, et al. Development of a portable rapeseed quality detection device based on near-infrared spectroscopy[J]. Transactions of the CSAE, 2024, 40(18): 13 – 22. (in Chinese)

[16] Wang L, Jin J, Song Z, et al. LeafSpec: an accurate and portable hyperspectral corn leaf imager[J]. Computers and Electronics in Agriculture, 2020, 169: 105209.

[17] Wang Y, Sun J, Wu Z, et al. Application of non-destructive technology in plant disease detection: review[J]. Agriculture, 2025, 15(15): 1670.

[18] Terentev A, Badenko V, Shaydayuk E, et al. Hyperspectral remote sensing for early detection of wheat leaf rust caused by Puccinia triticina[J]. Agriculture, 2023, 13(6): 1186.

[19] Castro-Valdcantos P, Egea G, Borrero C, et al. Detection of fusarium wilt-induced physiological impairment in strawberry plants using hyperspectral imaging and machine learning[J]. Precision Agriculture, 2024, 25(6): 2958 – 2976.

[20] 陈绍民,徐芝霖,高嘉晨,等. 基于低空遥感光谱与纹理信息的冬马铃薯冠层等效水厚度反演[J]. 农业机械学报,2026, 57(2):290 – 300.
Chen Shaomin, Xu Zhilin, Gao Jiachen, et al. Inversion of canopy equivalent water thickness of winter potato based on low-altitude remote sensing spectral and textural information[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(2): 290 – 300. (in Chinese)

[21] 杨福芹,李昌浩,张英发,等. 融合高光谱和数码影像的冬小麦氮营养指数遥感监测[J]. 光谱学与光谱分析,2025, 45(6):1719 – 1728.
Yang Fuqin, Li Changhao, Zhang Yingfa, et al. Remote sensing monitoring of winter wheat nitrogen nutrition index by fusing hyperspectral and digital images[J]. Spectroscopy and Spectral Analysis, 2025, 45(6): 1719 – 1728. (in Chinese)

[22] 齐浩,孙海芳,吕亮杰,等. 基于无人机多光谱信息与纹理特征融合的小麦叶面积指数估测[J]. 农业机械学报,2025, 56(3):334 – 344.
Qi Hao, Sun Haifang, Lü Liangjie, et al. Estimation of wheat leaf area index based on fusion of uav multispectral information and textural features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 334 – 344. (in Chinese)

[23] Jiang Q, Wang H, Wang H. Severity assessment of wheat stripe rust based on machine learning[J]. Frontiers in Plant Science, 2023, 14: 1150855.

[24] Bai G, Zhang T, Cai L, et al. Multimodal fusion-based classification method for small-sample imperfect wheat kernels using hyperspectral imaging[J]. Food Control, 2026, 185: 112034.

[25] Zhang X, Guan H, Zhao J, et al. Drought resistance classification of wheat varieties by multisource data fusion and machine learning via hyperspectral and thermal infrared imaging[J]. Chemical and Biological Technologies in Agriculture, 2025, 12(1): 165.