doi:10.6041/j.issn.1000-1298.2026.12.026

基于光谱优化和 Transformer 的香蕉叶斑病早期检测方法

段洁利[1]　柯伟贵[1]　袁浩天[1]　蒋寅龙[1]　钟映已[1]　冯淑杰[2]　杨　洲[1,3]

(1. 华南农业大学工程学院, 广州 510642; 2. 华南农业大学园艺学院, 广州 510642;
3. 广东海洋大学机械工程学院, 湛江 524088)

摘要: 香蕉叶斑病是香蕉生产危害叶片最常见的真菌性病害之一,其潜伏期诊断对于实现早期的精准防控与优化农药施用策略具有重要意义。本文提出一种结合光谱优化方法和 Transformer 的模型,构建了香蕉叶斑病早期诊断模型。模型基于健康、潜伏期和发病的香蕉叶斑病苗期叶片高光谱图像为研究对象,提取其感兴趣区域内平均光谱,通过对光谱预处理方法和特征波段选择方法进行研究,排列组合得到 30 种光谱优化处理方法,确定最佳光谱优化处理方法是卷积平滑法(SG)结合一阶导数(D1)预处理,再使用竞争自适应重加权算法(CARS)进行波段选择。基于优化光谱数据构建的 Transformer 模型总体准确率达 91.78%,较未优化光谱模型提升 12.21 个百分点。试验结果表明,本文提出的 SG-D1-CARS 光谱优化处理方法能够有效地减少光谱数据间的影响,消除冗余信息,优化光谱谱带,为实现香蕉叶斑病早期检测提供了理论和技术支持。

关键词: 香蕉叶斑病; 光谱预处理; 特征波段提取; 早期检测

中图分类号: S24; S668.1　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)12-0275-10　　**OSID**:

Early Detection Method for Banana Leaf Spot Disease Based on Spectral Optimization and Transformer

DUAN Jieli[1]　KE Weigui[1]　YUAN Haotian[1]　JIANG Yinlong[1]　ZHONG Yingji[1]　FENG Shujie[2]　YANG Zhou[1,3]

(1. *College of Engineering, South China Agricultural University, Guangzhou* 510642, *China*
2. *College of Horticulture, South China Agricultural University, Guangzhou* 510642, *China*
3. *College of Mechanical Engineering, Guangdong Ocean University, Zhanjiang* 524088, *China*)

Abstract: A rapid early diagnosis model for banana leaf spot disease was constructed and evaluated by combining spectral optimization methods with a Transformer model. The investigation was motivated by the fact that banana leaf spot disease is among the most common fungal diseases that damage banana leaves. It is widely recognized that early diagnosis, achieved before symptom manifestation, is crucial for enabling precise early intervention and optimized pesticide use. The hyperspectral images of healthy, diseased, and asymptomatic samples were collected, and the average spectral data of region of interest between 400 nm and 900 nm bands was extracted. In response to the problem of mutual interference in hyperspectral data of banana leaf spot disease with different severity levels, as well as the decrease in prediction accuracy caused by the large number of bands, large data volume, and complex spectral bands, spectral preprocessing methods and feature band selection methods were studied. Four preprocessing algorithms, Savitzky-Golay convolution smoothing (SG), standard normal transformation (SNV), first derivative (D1), and multiple scattering correction (MSC), and their combined model effects were compared and analyzed. Principal component analysis (PCA), continuous projection algorithm (SPA), and competitive adaptive reweighting algorithm (CARS) were used for feature wavelength extraction. By combining these methods, a total of 30 spectral processing methods were obtained, which were then combined with the Transformer model with center loss added to establish optimized discriminant models. Based on the average accuracy of the established discriminant models, the

收稿日期: 2025-12-08　修回日期: 2026-01-17

基金项目: 国家自然科学基金项目(32572186)、广东省现代农业产业技术体系创新团队建设项目(2024CXTD09)、财政部和农业农村部:国家现代农业产业技术体系项目(CARS-31-11)和广州市科技计划项目(2023B03J1393)

作者简介: 段洁利(1973—),女,教授,博士生导师,主要从事智能农业装备研究,E-mail: duanjieli@scau.edu.cn

通信作者: 杨洲(1972—),男,教授,博士生导师,主要从事水果生产机械化与信息化研究,E-mail: yangzhou@scau.edu.cn

optimal spectral processing method suitable for early detection of banana leaf spot disease was finally selected. The research results showed that the classification accuracy of optimized spectral data using 22 spectral processing methods was significantly improved compared with the overall classification accuracy of 79.57% for the original data. The optimal spectral processing method was SG - D1 - CARS, combined with the confusion matrix. The Transformer model constructed based on optimized spectral data achieved an overall accuracy of 91.78%, an improvement of 12.21 percentage points compared with that of the unoptimized spectral model. The experimental results indicated that the proposed method can effectively detect banana leaf spot disease in the early stage. By combining various preprocessing and feature extraction methods based on optimization objectives, the modeling effect can be effectively improved, providing theoretical and technical support for non-destructive, accurate, and intelligent detection of crop diseases.

Key words: banana leaf spot disease; spectral preprocessing; feature band extraction; early detection

0 引言

香蕉在种植过程常受到各种病害影响,导致大量减产,严重影响香蕉产业发展[1-2]。香蕉叶斑病是香蕉生产上危害叶片最常见的真菌性病害,可防可治,但严重时会引起香蕉叶片早衰和枯死,给生产带来严重损失[3-4]。目前防治香蕉叶斑病的农药主要是传统的丙环唑、戊唑醇、吡唑醚菌酯等[5-6],不同病变程度的香蕉叶斑病对应的用药种类及用药剂量也各不相同,为实现早期精准防控,优化农药施用策略、降低施用量,亟需一种在香蕉叶斑病症状显症之前实现早期诊断的方法。

随着科学技术快速发展,图像处理技术、人工智能技术、光谱检测技术等被广泛应用到农业领域,光谱检测成为植物叶片病害无损检测识别的重要方法[7-8]。在高光谱数据分析过程中,有效提高信噪比、合理选择光谱优化方法至关重要[9-10]。GAO 等[11]利用蒙特卡洛采样光谱预处理方法结合最小二乘支持向量机模型识别葡萄卷叶病受感染的不同程度,准确率可达 89.93%。ZHANG 等[12]利用主成分分析(Principal component analysis, PCA)光谱优化方法中的第二主成分图像和 680/715 波段比图像,结合简单的阈值方法,检测柑橘 4 种病害的茎尖分类准确率达到 96.63%。上述研究均为对肉眼可见病害的检测。

JIANG 等[13]使用连续投影算法(Successive projections algorithm, SPA)的光谱优化方法结合随机森林模型来实现对红树林叶片中不同病害的早期检测。文献[14-15]通过对梨果的光谱图像经标准正态变量变换、一阶导数、二阶导数及组合预处理后,利用主成分分析进行数据降维结合分类器证实了高光谱具有监测果实发病的能力。这些研究通过寻找最优的光谱优化方法,针对特定作物实现了肉眼和 RGB 图像无法识别的早期病害检测。然而,目前在香蕉叶斑病早期检测中,尚缺乏专门针对该病害的、系统性的光谱优化方法研究。因此,针对香蕉叶斑病寻找最优的光谱优化方法,对实现香蕉叶斑病快速无损的早期检测具有重要意义。

需要指出的是,虽然田间自然发病环境更为复杂,但受控环境下的离体组织研究是解析病害早期光谱特征的基础。彭铁成等[16]研究表明,经适当保湿处理的离体香蕉叶片可有效模拟病原菌侵染过程。MAHLEIN 等[17]指出标准化的离体接种试验能够精确控制病原菌侵染时间,排除田间复杂光照和环境背景的干扰,从而准确捕捉病原菌侵染引起的微弱光谱指纹信息。MAO 等[18]在实验室内寻找出茶叶灰斑病的敏感波段,在实验室理想条件下,准确率达 92.6%,在田间应用准确率达到 87.8%。目前已有研究使用离体叶片结合高光谱进行病害检测研究[19-20]。

针对上述问题,本文以香蕉苗期叶片为研究对象,采用贴菌丝块离体接种法[21]进行染病,精确控制感染时间并排除环境光、风速等干扰,捕捉香蕉叶斑病潜伏期微弱的光谱指纹信息为原始数据,结合高光谱成像技术,对 4 种预处理方法、3 种特征提取方法及其组合,结合改进后的 Transformer 构建的 30 种模型进行对比寻优,以期找到一种快速无损的香蕉叶斑病潜伏期检测方法,为香蕉病害早期检测及提早预防提供有效手段。

1 材料与方法

1.1 试验材料

于华南植物园香蕉种植基地选取 6~7 叶期的香蕉幼苗 100 株,每株剪取健康叶片 2 片,共 200 片叶片作为试验对象。将其中 100 片作为健康对照组,另 100 片采用叶片贴菌丝块接种法接种,致病菌为从田间发病香蕉植株叶片上分离得到的球黑孢霉叶斑病病菌,以更好地模拟田间实际情况,满足后续病害检测需求,菌饼规格为 7 mm × 7 mm,每个叶片接种 2 个部位。为消除离体叶片失水对光谱数据的

干扰，接种完成后，将叶柄基部用吸水纸包裹并喷洒无菌水后置于底部铺设有无菌水饱和滤纸的保鲜盒内，盖好盒盖，再将保鲜盒置于相对湿度 95% 以上，环境温度 25℃ 的恒温恒湿光照培养箱中。每 24 h 采集 1 次高光谱图像，每次时间控制在 2 min 内，动态追踪接种叶片的发病过程。接种叶片陆续会在 1 d 后至 3 d 内出现肉眼可见病斑。所有处理组（健康、潜伏期、发病）均执行相同保湿与采集流程，保证试验条件一致性。

最终有 68 个叶片成功接种。根据病症显现情况，将叶片分为 3 类：接种后未出现病斑阶段记为潜伏期叶片；接种后出现病斑阶段记为发病叶片；未接种叶片记为健康叶片（对照组，共 100 片）。

1.2　高光谱采集

高光谱采集使用奥普天成（Optosky）ATH1010 型高光谱成像系统，其波段为 350 ~ 1 000 nm。该系统组成如图 1 所示，主要包括计算机、成像光谱仪、3 个 200 W 卤素光源、丝杠滑台及步进电机。成像光谱仪核心组件为 CCD 摄像机与光谱仪。为减少环境光照对成像的影响，整个系统置于室内，并用黑色遮光布遮蔽。成像前，系统需预热 15 min 以达到稳定状态，旨在最小化试验过程中潜在干扰因素。关键成像参数设置为：CCD 相机曝光时间 3 500 μs；光谱分辨率 1.25 nm；相机帧率 77 f/s；丝杠滑台移动速度 3.94 cm/s；镜头至叶片距离 70 cm。

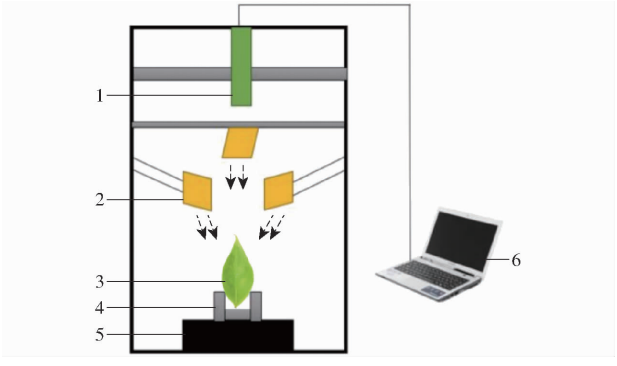

图 1　香蕉叶斑病高光谱图像采集

Fig. 1　Collecting hyperspectral images of leaf spot disease

1. 高光谱相机　2. 卤素灯　3. 香蕉叶片　4. 托盘　5. 底座　6. 计算机

1.3　黑白校正

为有效消除环境光照对原始高光谱数据造成的噪声干扰，需执行黑白校正操作。校正过程要求预先获取相应的暗电流参考帧（R_{Di}）与白板参考帧（R_{Wi}）。暗电流参考帧采集需在完全遮蔽镜头（覆盖镜头盖）条件下进行，以获取单帧暗背景数据。单帧白板参考帧采集则需将反射率为 99% 的标准漫反射白板置于成像仪正前方，并确保其完全覆盖镜头整个视场角。最终，对原始叶片高光谱反射率（R_i）进行校正计算，从而获得校正后高光谱图像，即

$$R_i = \frac{R_{Si} - R_{Di}}{R_{Wi} - R_{Di}} \tag{1}$$

式中　R_{Si}——样本 DN 值

1.4　高光谱图像数据预处理

1.4.1　感兴趣区域信息提取

对校正后高光谱图像，使用 ENVI 5.3 提取不同病变程度叶片的感兴趣区域（Region of interest，ROI）[22]，本文“样本（Sample）”均指感兴趣区域。

ROI 选取规则为：对潜伏期叶片和发病叶片，在病斑接种区域选取尽可能多的 30 像素 ×30 像素圆形区域；对健康叶片，在避开叶脉及边缘的区域随机选取尺寸相同的圆形区域，以发病叶片为例的 ROI 选取规则如图 2 所示。潜伏期叶片采集的 ROI 定义为无症状染病样本，发病叶片采集的 ROI 定义为有症状染病样本，健康叶片采集的 ROI 定义为健康样本。最终共获取 1 079 个样本，包括健康样本 380 个、无症状染病样本 368 个、有症状染病样本 331 个。计算所有 ROI 的平均光谱反射率，得到单叶片样品反射率曲线。剔除 350 nm 及 1 000 nm 附近受噪声影响较大的波段，选择 400 ~ 900 nm 间 373 个波段作为有效光谱数据。图 3 为所有香蕉叶片原始光谱曲线。

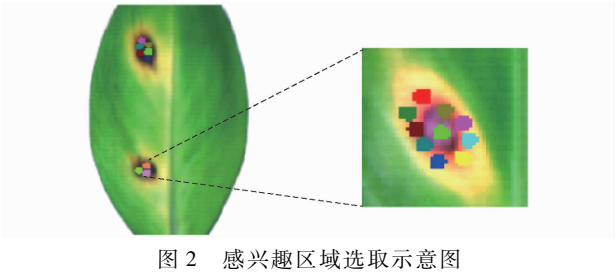

图 2　感兴趣区域选取示意图

Fig. 2　Schematic for selecting regions of interest

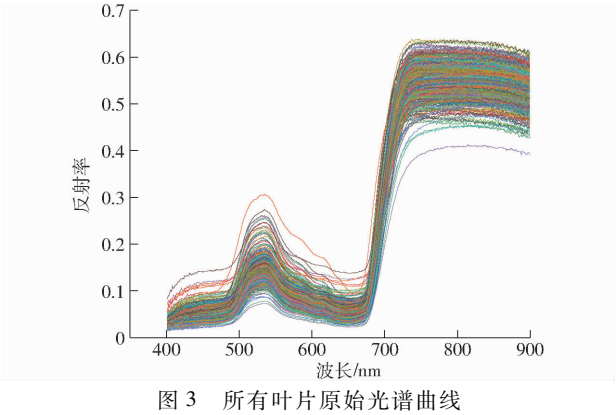

图 3　所有叶片原始光谱曲线

Fig. 3　Original spectral curves for all leaves

不同病变程度香蕉叶片平均光谱如图 4 所示，从光谱曲线整体走势看，均呈绿色植物的光谱特征，

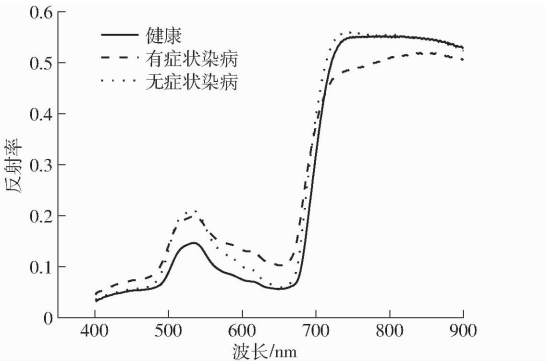

图 4 不同病变程度平均光谱曲线

Fig. 4 Average spectral curves of different degrees of lesions

在 550 nm 附近是叶绿素的强反射峰,680 nm 左右是叶绿素的强吸收作用引起的“红谷”,700 ~ 760 nm 光谱反射率出现一个较大的跃变,760 nm 后反射率变化趋缓。由图 4 可以看出,400 ~ 550 nm 无症状染病样本和有症状染病样本光谱较为相似,700 ~ 900 nm 健康样本和无症状染病样本光谱较为相似。发病叶片相较于健康叶片以及潜伏期叶片,光合作用能力下降,叶绿素含量降低,导致对红光的吸收减弱,在 680 nm 处,反射率增大;发病叶片中含水率偏低,导致 700 nm 以后的波段区域内反射率低。不同叶片的光谱具有其自身的独特性,且不完全一致,依靠曲线还无法精细分类。

1.4.2 光谱信息预处理

针对无症状染病样本数据易与有症状染病样本数据和健康数据混淆,以及为消除测量环境因素及高光谱相机性能不足所致的数据基线漂移与噪声干扰,需对原始样本光谱实施预处理以提升信噪比[23-24]。采用卷积平滑法(Savitzky-Golay, SG)、标准正态变换(Standard normal variate, SNV)、多元散射校正(Multiple scattering correction, MSC)及一阶导数(First derivative, D1)作为预处理方法,以健康数据处理为例,相应处理结果如图 5 所示。

1.4.3 特征波段提取方法

高光谱技术能够获取针对植物叶片表面的多种物理、化学和生理信息,同时,也会带来较多冗余信息,对模型分类速度及精度会产生一系列影响[25]。从高光谱数据的全部波段中提取出具有区分特征的波段子集进行分析,能够降低数据维度,简化分类模型构建,以此提高模型效率及鲁棒性[26-27]。采用主成分分析(Principal component analysis, PCA)、竞争自适应重加权算法(Competitive adaptive reweighted sampling, CARS)、连续投影算法(Successive projections algorithm, SPA)3 种方法对香蕉叶片高光谱数据进行特征变量提取。

PCA 为常用的数据降维方法,可通过线性变换将原始光谱数据压缩成一组新的正交变量,使其在去除冗余信息的同时解决数据线性相关的问题。CARS 竞争性自适应重加权采样是一种启发式波段选择算法,模拟达尔文进化理论中的“适者生存”原则,尤其适用于高维光谱数据中的关键变量提

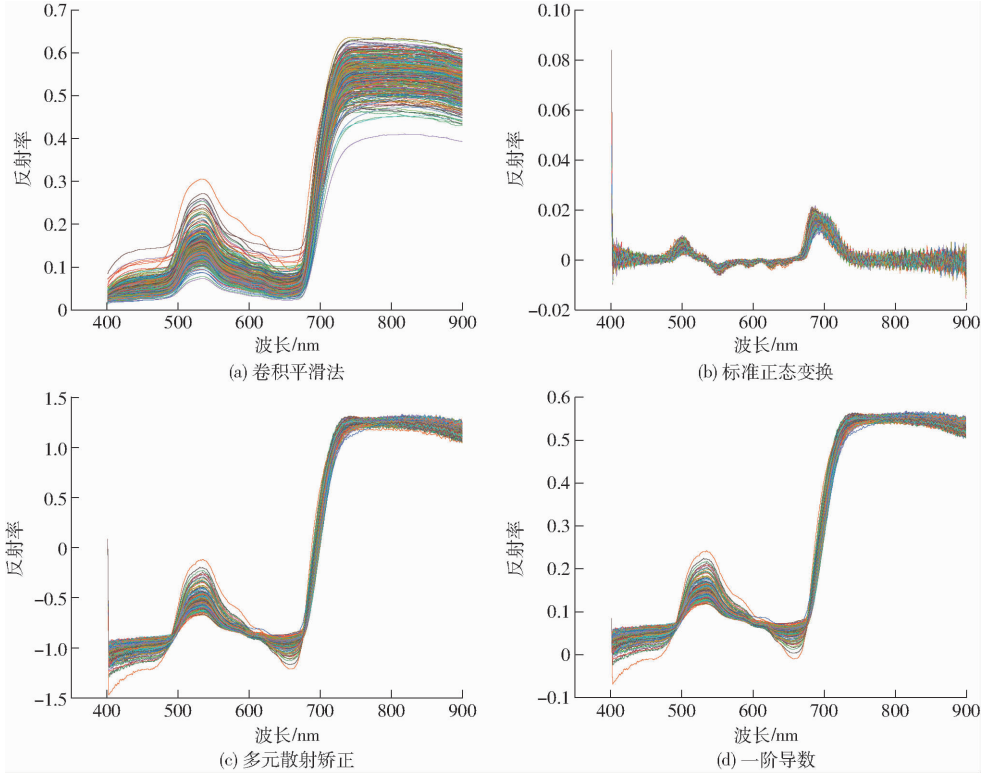

图 5 不同预处理光谱曲线

Fig. 5 Different preprocessed spectral curves

取[28]。SPA 连续投影算法是一种基于前向迭代投影机制的波段选择算法，常用于消除高维光谱数据的多重共线性问题[29]。

1.4.4　模型选取及改进

Transformer 网络[30]是一种基于自注意力机制的深度学习架构，由于其强大的序列建模能力、并行化计算优势以及对全局依赖关系的高效捕捉特性，被广泛应用于多模态数据分析领域。本研究输入数据为香蕉叶斑病不同病变程度的光谱数据，其维度为 373（特征/波段数）×1（通道数）。基于多次调参测试，最终构建的 Transformer 分类模型包含 2 层编码器层（N 为 2），每层包含 4 个注意力头。模型嵌入维度设置为 64，前馈网络维度设置为 128。此模型架构旨在捕捉光谱波段间复杂的依赖关系，以进行不同病变程度的分类识别。

损失函数用于衡量模型预测与真实标签之间的差异。使用交叉熵损失（Cross-entropy loss）作为主要损失函数，其能够刻画模型预测概率分布与实际概率分布之间的差异。对于多分类任务，交叉熵损失公式为

$$L_{CE} = -\sum_{i=1}^{N} x_i \ln y_i \tag{2}$$

式中　L_{CE}——交叉熵损失

N——类别数量

x_i——样本在类别上的真实标签

y_i——模型预测概率，即 Softmax 输出值

为增强类内一致性并提高分类边界的判别性，在交叉熵损失的基础上引入中心损失（Center loss）作为辅助监督信号。中心损失通过约束同类样本的特征向量向该类别的中心聚拢，有效缩小类内距离，公式为

$$L_{CL} = \frac{1}{2}\sum_{i=1}^{m} \| \boldsymbol{a}_i - \boldsymbol{c}_{bi} \|_2^2 \tag{3}$$

式中　m——样本个数

L_{CL}——中心损失

$\boldsymbol{a}_i$——第 i 个样本特征向量

$\boldsymbol{c}_{bi}$——第 b_i 个类别中心向量

最终的损失函数由交叉熵损失和中心损失加权组成，即

$$L = L_{CE} + \lambda L_{CL} \tag{4}$$

式中　L——损失　　λ——中心损失权重

通过优化该联合损失函数，最终 λ 选定为 0.1，模型在训练过程中不仅能有效区分不同类别，还能使得同类样本在特征空间中更加紧凑，从而提升整体分类性能。使用上述分类算法构建香蕉叶斑病早期检测模型如图 6 所示，通过自注意力机制能有效建模波段间复杂的非线性关系，中心损失引入则增强了分类边界判别性，在病害早期检测任务中表现出色。

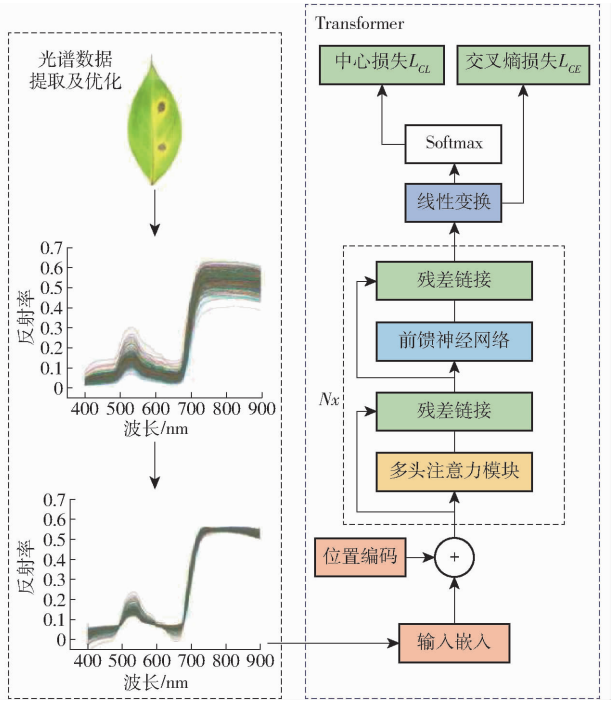

图 6　香蕉叶斑病早期检测模型

Fig. 6　Early detection model of banana leaf spot disease

试验在配备 Intel Core i7 - 13700K CPU、32G DDR4 内存和 RTX 4060 Ti 显卡的计算机上进行。操作系统为 Windows 10 专业版，所有代码使用 Python 3.8 编写，深度学习框架为 PyTorch 1.7.1，并搭配 CUDA 11.0 和 cuDNN 8.0 以利用 GPU 加速训练。

2　结果与分析

2.1　样本划分

为减少随机性影响、获得更准确的性能评估，利用多次随机划分的方法，将不同病变程度样本多次随机按比例 7∶3 分为训练集和测试集。仅在训练集上执行预处理，并利用训练集参数对测试集进行相同变换，最后在训练集上进行数据增强，以避免数据泄露。采用平均分类准确率以及平均 Kappa 系数进行模型性能评估，各参数越大说明分类效果越好。测试集不参与建模，仅用于评测模型准确率，具体划分结果如表 1 所示。

表 1　香蕉叶斑病样本划分

Tab. 1　Sample division of banana leaf spot disease

样本类型	健康	无症状染病	有症状染病
原始数据	380	368	331
数据增强后	646	626	563
训练集	532	516	464
测试集	114	110	99

利用添加高斯噪声的方法进行数据增强，在实际测量中会引入各种噪声，如传感器噪声、暗电流等，这些噪声通常符合高斯分布，因此，添加高斯噪声可模拟这些实际测量中的噪声，使模型在训练时适应这种干扰，提高在实际应用中的鲁棒性。

2.2 光谱预处理结果

对 3 类样本的光谱曲线使用 1.4.2 节给出的 4 种光谱预处理方法及其组合，得到全光谱识别准确率如表 2 所示。经光谱预处理后，除单独使用 SG、MSC 外，其余预处理方法在分类模型下的平均识别准确率均得到提升，这是由于单独使用 SG、MSC 时过度的平滑会导致一些有效信息丢失、准确率下降，其中 MSC－D1 识别准确率最高，达到 88.04%。

表 2 全光谱识别准确率

Tab.2 Full spectrum recognition accuracy %

预处理方法	Transformer	Transformer－Center
RAW	77.24	79.57
SG	72.47	74.54
MSC	73.88	75.00
SNV	80.25	81.25
D1	80.96	82.41
SG－MSC	67.66	68.98
SG－SNV	81.73	83.10
SG－D1	84.76	86.87
MSC－SNV	78.88	80.37
MSC－D1	86.87	88.04
SNV－D1	85.76	86.99

中心损失可以约束同类样本在特征空间中的分布，缩小类内距离。本研究所涉及的健康、有症状染病与无症状染病 3 类样本光谱特征较为接近，引入中心损失有效强化类内一致性，从而增强分类边界的判别性。从表 2 可看出，Transformer－Center 作为引入中心损失后的 Transformer，所有预处理方法对应的模型识别准确率均获得提升。

2.3 基于竞争自适应重加权算法的特征波段提取

竞争自适应重加权算法（CARS）具备有效压缩数据并筛选最优特征波长组合的能力。本研究蒙特卡洛采样次数设定为 50。图 7a～7c 为 CARS 算法从原始光谱（RAW）中提取特征波长的具体过程。

图 7a 为蒙特卡洛采样次数递增条件下，提取的特征波段数变化趋势：其数量随采样次数增加而急剧减少，之后变化渐趋平稳。图 7b 为迭代过程中均方根误差（RMSE）的演变，RMSE 在第 13 次迭代时达到最小值，表明该点为最优迭代次数。具体而言，在此最优迭代次数前，CARS 通过筛选特征波长有效剔除了与香蕉叶斑病无关的光谱变量；超过此点后，尽管迭代次数增加仍能缓慢减少特征波长数量，但同时伴随 RMSE 的显著上升。这一现象表明，过度迭代会剔除与香蕉叶斑病相关的特征波长，导致模型精度降低。图 7c 为各特征波长回归系数在蒙特卡洛迭代过程中的路径变化。图中红色垂直实线标定了 RMSE 最小值位置（即第 13 次迭代），其右侧区域 RMSE 开始升高。

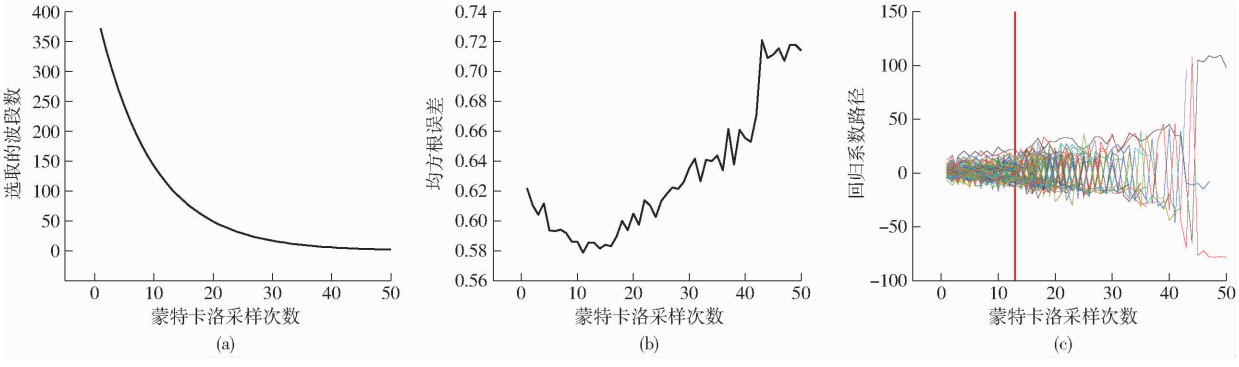

图 7 CARS 算法的波长变量筛选过程

Fig.7 Wavelength variable screening process of CARS algorithm

基于 RMSE 最小化准则[31]，最终确定第 13 次迭代为最优迭代点。在此条件下，RMSE 取得最小值，CARS 算法成功筛选并保留了 93 个特征波长。

2.4 基于主成分分析算法的特征波段提取

采用主成分分析（PCA）算法对香蕉叶斑病的高光谱数据进行降维处理。由表 3 可知：第一主成分（PC1）贡献率最高，达 45.91%；第二主成分（PC2）贡献率为 38.49%。前 2 主成分累积贡献率达 84.40%，前 3 主成分累积贡献率提升至 96.37%。随着主成分数量增加，累积贡献率增量呈递减趋势。一般选择主成分个数的常规标准为方差累积贡献率达 85% 以上，为尽可能地利用光谱特征信息，选取前 3 主成分用于后续的分析建模[32]。载荷反映了主成分与不同波长的相关系数，同时表达了两者的密切程度，每条主成分曲线的波峰或波谷处表示局部最大的权重系数，该位置对应的波段即为提取出的特征波段，前 3 主成分载荷曲线如图 8 所示。通过寻找各主成分曲线的极值，得到 50 个特征波长。

表 3　前 7 主成分特征值和累积贡献率

Tab. 3　Eigenvalues and cumulative contribution rates of the first seven principal components

主成分	特征值	累积贡献率/%
PC1	170.936 5	45.91
PC2	143.309 1	84.40
PC3	44.566 0	96.37
PC4	9.097 5	98.81
PC5	1.829 2	99.30
PC6	1.029 9	99.58
PC7	0.311 2	99.66

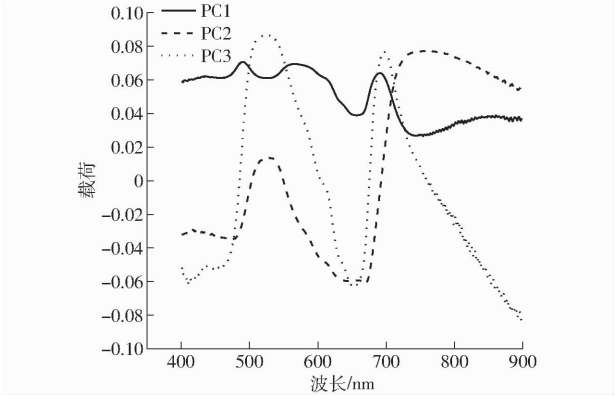

图 8　前 3 主成分载荷曲线

Fig. 8　Load curves of the first three principal components

2.5　基于连续投影算法的特征波段提取

连续投影算法(SPA)旨在从原始光谱数据中筛选出包含最低冗余信息量的特征波长组合,以最小化特征波长间的共线性,同时最大限度保留原始数据中的大部分有效信息。以 SPA 对 RAW 光谱数据进行特征波长提取的结果为例。图 9a 为筛选过程中 RMSE 随特征波段数量增加的变化趋势,可见,当特征波长数增至 29 后,RMSE 趋于平缓(此时 RMSE 为 0.627 7)。最终选取 29 个特征波长作为最优解的依据为:在此数量后,RMSE 无显著降低。使用过多的波长参与建模不仅可能导致引入噪声,更会增加模型的复杂度及过拟合风险。图 9b 为最终筛选得到的 29 个特征波长在原始光谱上的分布位置。图中经红色方块标注位置为由 SPA 筛选得到的特征波段。

2.6　光谱预处理算法与特征提取算法结合

扩展 10 种光谱预处理方法,分别与 CARS、PCA 和 SPA 3 种特征波段提取算法进行组合,共形成 30 种光谱处理技术,如表 4 所示。由于光谱数据预处理与特征波段提取旨在解决不同问题,优化数据特性与筛选信息变量,该组合策略旨在更全面地优化光谱数据质量,提升建模性能。

由表 4 可知,应用 CARS、PCA 和 SPA 均能有效消除不同数量的冗余信息,从而筛选出更具代表性

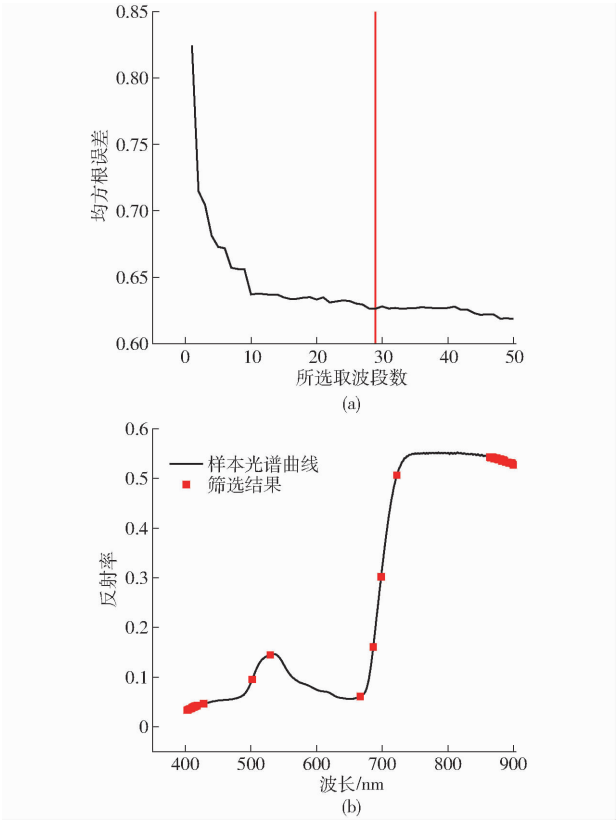

图 9　SPA 算法波长变量筛选过程

Fig. 9　Wavelength variable screening process of SPA algorithm

表 4　不同光谱处理方法提取得到的特征波段数

Tab. 4　Number of characteristic bands extracted by different spectral processing methods

方法	RAW	CARS	PCA	SPA
RAW	373	93	50	29
SG	373	44	50	50
MSC	373	93	50	46
SNV	373	93	50	34
D1	373	75	50	44
SG－MSC	373	103	50	37
SG－SNV	373	93	50	42
SG－D1	373	93	50	31
MSC－SNV	373	93	50	36
MSC－D1	373	128	50	46
SNV－D1	373	128	50	37

的特征波段。且由于 Transformer 结构的处理速度随着数据增大呈几何倍增长,波段提取还能有效地提高模型训练速度。

2.7　建模结果分析

将所选择特征波长作为新光谱数据输入改进后的 Transformer 分类模型,对香蕉叶斑病不同病变程度进行分类(分类结果见表 5)。经过 PCA、SPA 波段选择后,模型准确率提升不明显,在 PCA 和 SPA 中,D1、MSC－D1、SNV－D1 等导数方法的准确率相对 RAW 或 CARS 出现了断崖式下跌,这是由于 PCA

表 5 不同光谱处理方法识别结果

Tab. 5 Recognition results of different spectral processing methods

预处理方法	RAW		CARS		PCA		SPA	
	准确率/%	Kappa 系数	准确率/%	Kappa 系数	准确率/%	Kappa 系数	准确率/%	Kappa 系数
SG	74.54	0.618 9	75.69	0.633 1	74.31	0.611 6	78.90	0.683 4
MSC	75.00	0.626 5	78.24	0.673 2	83.80	0.756 6	76.93	0.652 5
SNV	81.25	0.719 3	90.25	0.853 6	81.71	0.725 0	79.39	0.690 5
D1	82.41	0.735 5	91.17	0.867 3	74.77	0.622 2	70.74	0.560 2
SG－MSC	68.98	0.533 3	83.13	0.745 3	71.06	0.566 9	78.04	0.668 1
SG－SNV	83.10	0.745 9	84.26	0.763 7	81.25	0.718 3	86.87	0.802 9
SG－D1	86.87	0.802 9	91.78	0.876 5	82.18	0.732 5	78.22	0.672 9
MSC－SNV	80.37	0.706 5	89.63	0.844 4	81.02	0.715 5	82.27	0.733 9
MSC－D1	88.04	0.820 3	90.43	0.856 2	74.66	0.619 0	73.01	0.593 9
SNV－D1	86.99	0.804 6	89.75	0.846 1	75.20	0.628 2	72.58	0.587 9

致力于找到方差最大的主成分方向。导数光谱(尤其是高阶导数)会放大高频噪声,这些噪声可能具有较大的方差,导致 PCA 主成分被噪声主导,而非被有效信号主导。SPA 是选择信息量最丰富的变量集合。导数处理可能会改变光谱的协方差结构,使得 SPA 选择的变量子集在原始空间中是有效的,但在导数空间中却失去了判别能力。经过 CARS 特征波段选择后对提升模型分类性能具有重要作用,均能在不同程度上提高模型总体分类精度。尤其是 D1、SG－D1 等方法,准确率超过 91%。CARS 会选择出与目标变量最相关的波长点。一阶导数处理后的光谱,其峰谷位置(即变化率最大的点)与物质成分高度相关。CARS 恰好能从这些导数光谱中筛选出最具判别力的波长点,起到了协同增效的作用。即使是 RAW 下很差的 SG－MSC,在 CARS 的帮助下提升至 83.13%。

表 5 识别结果验证了本文光谱处理流程结合改进后的 Transformer 模型在香蕉叶斑病早期检测中的有效性,同时表明光谱预处理与特征波段提取的协同使用可实现方法的优势互补。其中,SG－D1－CARS 处理效果最佳,其分类平均准确率达到 91.78%,平均 Kappa 系数为 0.876 5。Kappa 系数趋近于 1 表示分类精度高,该结果说明基于 SG－D1－CARS 处理与改进后的 Transformer 模型能够实现对香蕉叶斑病不同病变程度的精准分类。通过该处理方法筛选出的特征波段主要集中于 3 个区域:①550 nm 附近的绿色反射峰,健康叶片在此波段反射率较高,而香蕉叶斑病侵染导致叶绿素降解,反射率显著降低。②红边区域(677～718 nm),病害进展会引起红边位置向短波方向移动(蓝移),其移动幅度与病变程度密切相关。③近红外水吸收带(860～890 nm),因病害破坏叶片细胞结构并影响水分代谢,导致该波段反射率变化。这些波段变化规律揭示了病害生理机制与光谱响应之间的关联。

为更直观评估各方法对香蕉叶斑病早期检测的识别效果,通过混淆矩阵进行进一步分析(以 RAW－RAW 和 SG－D1－CARS 为例,如图 10 所示)。图 10 中,颜色越白对应的预测相似率的相似度越低,越蓝相似度越高,矩阵的正确分类集中在矩阵对角线上,如果混淆矩阵对角线相似度越高,则认为该模型分类效果较好。结果表明基于 SG－D1－CARS 方法构建的针对香蕉叶斑病早期检测结果精度明显提高,分类性能的稳定性也明显提升,3 种不同病变

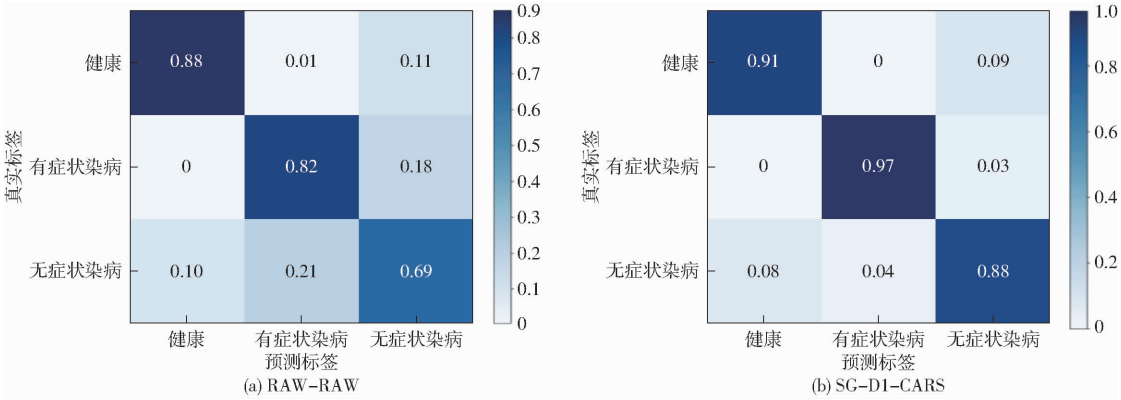

图 10 Transformer 分类模型混淆矩阵结果

Fig. 10 Confusion matrix result of Transformer classification model

程度的香蕉叶斑病光谱数据之间存在相互干扰，由图 10a 可看出，原始 RAW－RAW 数据中，有症状染病和无症状染病 2 种类别易混淆造成错误分类。由图 10b 可看出，经 SG－D1－CARS 光谱处理后的光谱数据能够降低不同病变程度香蕉叶斑病光谱数据之间存在的相互干扰，提高模型分类性能，对无症状染病叶片检测准确率达 88%，对有症状染病叶片检测准确率达 97%。

3　结论

（1）构建的光谱优化－Transformer 融合模型可实现香蕉叶斑病潜伏期早期诊断，总体准确率达 91.78%，为田间精准防控提供新方法。

（2）针对香蕉叶斑病早期检测改进 Transformer 模型，引入中心损失监督模型训练，对不同光谱优化方法都显著提高了模型分类准确率，证明了中心损失在香蕉叶斑病早期检测中的积极作用。

（3）SG－D1－CARS 方法最优，对无症状染病叶片检测准确率达 88%，对有症状染病叶片检测准确率达 97%。结果表明，该模型可指导农户分辨香蕉叶斑病病变程度，优化农药施用策略，有效实现香蕉叶斑病精准防控。

参　考　文　献

[1] 漆艳香，张欣，丁兆建，等. 香蕉病害名录[J]. 热带农业科学，2019,39(1):58－69.
QI Yanxiang, ZHANG Xin, DING Zhaojian, et al. A list of diseases on banana(*Musa* spp.)[J]. Chinese Journal of Tropical Agriculture, 2019,39(1):58－69. (in Chinese)

[2] 黄媛媛，徐小俊. 全球香蕉产业现状与发展趋势[J]. 热带农业工程，2021,45(5):34－38.
HUANG Yuanyuan, XU Xiaojun. Current situation and development trend of banana industry in global[J]. Tropical Agricultural Engineering, 2021,45(5):34－38. (in Chinese)

[3] 曾莉，郭志祥，番华彩，等. 云南香蕉病虫害危害现状及防治策略[J]. 热带农业科技，2011,34(3):18－22.
ZENG Li, GUO Zhixiang, FAN Huacai, et al. Pests and diseases damaged banana in Yunnan and their control[J]. Tropical Agricultural Science & Technology, 2011,34(3):18－22. (in Chinese)

[4] 桑利伟，郑服丛. 我国香蕉的主要病害及防治[J]. 安徽农业科学，2006(9):1841－1845.
SANG Liwei, ZHENG Fucong. Main diseases of banana and its control[J]. Journal of Anhui Agricultural Sciences, 2006(9):1841－1845. (in Chinese)

[5] 扶艳萍，漆艳香，谢艺贤，等. 香蕉灰纹病的病原鉴定及其生物学特性[J]. 热带生物学报，2021,12(1):63－71.
FU Yanping, QI Yanxiang, XIE Yixian, et al. Identification and biological characteristics of the pathogen causing cordana leaf spot of banana in Hainan Province[J]. Journal of Tropical Biology, 2021,12(1):63－71. (in Chinese)

[6] 潘连富，杜婵娟，杨迪，等. 氯氟醚菌唑悬浮剂对香蕉叶斑病的防治效果研究[J]. 中国南方果树，2021,50(4):51－54.

[7] 李艳雪，吕芳. 向日葵叶部病害图像分割方法[J]. 计算机技术与发展，2019,29(5):148－151.
LI Yanxue, LÜ Fang. Image segmentation method of sunflower leaf disease image[J]. Computer Technology and Development, 2019,29(5):148－151. (in Chinese)

[8] 刘浪，许金钗，翁海勇，等. 基于多光谱成像技术的水稻叶部病害检测装置设计与试验[J]. 福建农林大学学报(自然科学版)，2023,52(2):280－284.
LIU Lang, XU Jinchai, WENG Haiyong, et al. Development of a portable detection device for rice leaf diseases using multispectral imaging[J]. Journal of Fujian Agriculture and Forestry University (Natural Science Edition), 2023,52(2):280－284. (in Chinese)

[9] BING L, SUN J, YANG N, et al. Identification of tea white star disease and anthrax based on hyperspectral image information [J]. Journal of Food Process Engineering, 2021,44(1):9.

[10] XIE Chuanqi, YANG Ce, HE Yong. Hyperspectral imaging for classification of healthy and gray mold diseased tomato leaves with different infection severities[J]. Computers and Electronics in Agriculture, 2017,135:154－162.

[11] GAO Zongmei, KHOT L R, NAIDU R A, et al. Early detection of grapevine leafroll disease in a red-berried wine grape cultivar using hyperspectral imaging[J]. Computers and Electronics in Agriculture, 2020,179:8.

[12] ZHANG Hailiang, ZHANG Shuai, DONG Wentao, et al. Detection of common defects on mandarins by using visible and near infrared hyperspectral imaging[J]. Infrared Physics & Technology, 2020,108:10.

[13] JIANG Xiapeng, ZHEN Jianing, MIAO Jing, et al. Assessing mangrove leaf traits under different pest and disease severity with hyperspectral imaging spectroscopy[J]. Ecological Indicators, 2021,129:13.

[14] PAN Tingtiao, CHYNGYZ E, SUN Dawen, et al. Pathogenetic process monitoring and early detection of pear black spot disease caused by *Alternaria alternata* using hyperspectral imaging[J]. Postharvest Biology and Technology, 2019,154:96－104.

[15] 刘媛媛，张凡，师琪，等. 基于高光谱和集成学习的库尔勒香梨黑斑病潜育期诊断[J]. 农业机械学报，2022,53(6):295－303.
LIU Yuanyuan, ZHANG Fan, SHI Qi, et al. Diagnosis of Korla pear black spot disease in incubation period based on hyperspectral imaging and ensemble learning algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(6):295－303. (in Chinese)

[16] 彭铁成，陈云云，罗静瑶，等. 香蕉枯萎病的离体叶片接种技术研究[J]. 广东农业科学，2012,39(10):7－9.

PENG Tiecheng, CHEN Yunyun, LUO Jingyao, et al. Research on in vitro leaves inoculation technique for banana fusarium wilt disease[J]. Guangdong Agricultural Sciences,2012,39(10):7 – 9. (in Chinese)

[17] MAHLEIN A K. Plant disease detection by imaging sensors-parallels and specific demands for precision agriculture and plant phenotyping[J]. Plant Disease, 2016, 100(2): 241 – 251.

[18] MAO Y, LI H, XU Y, et al. Early detection of gray blight in tea leaves and rapid screening of resistance varieties by hyperspectral imaging technology[J]. Journal of the Science of Food and Agriculture, 2024, 104(15): 9336 – 9348.

[19] 张昭, 王鹏, 姚志凤, 等. 基于多光谱荧光成像技术和 SVM 的葡萄霜霉病早期检测研究[J]. 光谱学与光谱分析, 2021, 41(3): 828 – 834.
ZHANG Zhao, WANG Peng, YAO Zhifeng, et al. Early detection of downy mildew on grape leaves using multicolor fluorescence imaging and model SVM[J]. Spectroscopy and Spectral Analysis, 2021, 41(3): 828 – 834. (in Chinese)

[20] 侯冰茹, 刘鹏辉, 张洋, 等. 基于马铃薯叶片光纤光谱信息的晚疫病患病程度预测[J]. 光谱学与光谱分析, 2022, 42(5): 1426 – 1432.
HOU Bingru, LIU Penghui, ZHANG Yang, et al. Prediction of the degree of late blight disease based on optical fiber spectral information of potato leaves[J]. Spectroscopy and Spectral Analysis, 2022, 42(5): 1426 – 1432. (in Chinese)

[21] 甘林, 兰成忠, 张雅玲, 等. 西藏墨脱枇杷新拟盘多毛孢叶斑病病原菌的鉴定及拮抗细菌的防病效果[J]. 果树学报, 2026,43(1):136 – 146.
GAN Lin, LAN Chengzhong, ZHANG Yaling, et al. Identification of the pathogens of loquat leaf spot caused by *Neopestalotiopsis* sp. in Medog and the effect of antagonistic bacteria on disease[J]. Journal of Fruit Science, 2026,43(1): 136 – 146. (in Chinese)

[22] 刘红芸, 吴雪梅, 李德仑, 等. 基于高光谱技术的采摘期烟叶水分含量研究[J]. 中国农机化学报, 2021,42(9):157 – 163.
LIU Hongyun, WU Xuemei, LI Delun, et al. Study on the moisture content of tobacco leaves during the picking period based on hyperspectral technology[J]. Journal of Chinese Agricultural Mechanization, 2021,42(9):157 – 163. (in Chinese)

[23] 汤文权,王巧华,杨烝,等. 基于多模型特征融合技术的皮蛋凝胶品质分级方法[J]. 农业机械学报, 2026,57(3): 377 – 386.
TANG Wenquan, WANG Qiaohua, YANG Zheng, et al. Quality grading method of preserved egg gel based on multi-model feature fusion technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026,57(3): 377 – 386. (in Chinese)

[24] 潘健, 祁雁楠, 陈鲁威, 等. 基于可见/近红外高光谱成像技术的梨树叶部病害识别研究[J]. 中国农机化学报, 2024, 45(8):162 – 169.
PAN Jian, QI Yannan, CHEN Luwei, et al. Study on identification of pear leaf disease based on hyperspectral imaging technology[J]. Journal of Chinese Agricultural Mechanization, 2024,45(8):162 – 169. (in Chinese)

[25] 李欣庭, 张峰, 冯洁. 卷积神经网络结合改进光谱处理方法用于马铃薯病害检测[J]. 光谱学与光谱分析, 2024, 44(1):215 – 224.
LI Xinting, ZHANG Feng, FENG Jie. Convolutional neural network combined with improved spectral processing method for potato disease detection[J]. Spectroscopy and Spectral Analysis, 2024,44(1):215 – 224. (in Chinese)

[26] 龙燕, 连雅茹, 马敏娟, 等. 基于高光谱技术和改进型区间随机蛙跳算法的番茄硬度检测[J]. 农业工程学报, 2019, 35(13):270 – 276.
LONG Yan, LIAN Yaru, MA Minjuan, et al. Detection of tomato hardness based on hyperspectral technology and modified interval random frog algorithm[J]. Transactions of the CSAE, 2019,35(13):270 – 276. (in Chinese)

[27] 金秀, 齐海军, 李绍稳. 基于动态时间弯曲的马铃薯干腐病发病期时序高光谱诊断方法[J]. 食品科学, 2018, 39(19):233 – 240.
JIN Xiu, QI Haijun, LI Shaowen. Diagnosis of symptom appearance of potato dry rot disease using time series hyperspectral imaging based on dynamic time warping[J]. Food Science, 2018,39(19):233 – 240. (in Chinese)

[28] LI Hongdong, LIANG Yizeng, XU Qingsong, et al. Key wavelengths screening using competitive adaptive reweighted sampling method for multivariate calibration[J]. Analytica Chimica Acta, 2009,648(1):77 – 84.

[29] ARAÚJO M C U, SALDANHA T C B, GALVÃO R K H, et al. The successive projections algorithm for variable selection in spectroscopic multicomponent analysis[J]. Chemometrics and Intelligent Laboratory Systems, 2001,57(2):65 – 73.

[30] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. arXiv preprint arXiv: 1706.03762, 2017.

[31] 秦立峰, 张熹, 张晓茜. 基于高光谱病害特征提取的温室黄瓜霜霉病早期检测[J]. 农业机械学报, 2020,51(11): 212 – 220.
QIN Lifeng, ZHANG Xi, ZHANG Xiaoqian. Early detection of cucumber downy mildew in greenhouse by hyperspectral disease differential feature extraction[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(11):212 – 220. (in Chinese)

[32] 康丽, 袁建清, 高睿, 等. 高光谱成像的水稻稻瘟病早期分级检测[J]. 光谱学与光谱分析, 2021,41(3):898 – 902.
KANG Li, YUAN Jianqing, GAO Rui, et al. Early detection and identification of rice blast based on hyperspectral image[J]. Spectroscopy and Spectral Analysis, 2021,41(3):898 – 902. (in Chinese)