

DOI: 10.13718/j.cnki.xdzk.2026.02.001

罗义维, 刘洪江, 李炜, 等. 药桑叶片分类及叶绿素含量预测 [J]. 西南大学学报(自然科学版), 2026, 48(2): 1-16.

药桑叶片分类及叶绿素含量预测

罗义维, 刘洪江, 李炜, 李里, 袁姜莲, 何宁佳

西南大学 资源昆虫高效养殖与利用全国重点实验室, 重庆 400716

摘要: 为推进药桑工厂化精准管理体系构建, 本研究首次建立了基于高光谱反射率的叶片生理状态分类模型, 并开发了叶绿素含量预测模型。模型构建过程中, 系统对比了 3 种样本集划分方法、5 种数据预处理方法和 5 种机器学习算法。采用随机数据集(Random Database, RD)分别结合由原始数据(RAW)和经多元散射校正(Multiplicative Scatter Correction, MSC)预处理数据构建的支持向量机(Support Vector Machine, SVM), 得到的 RD-RAW-SVM 模型和 RD-MS-C-SVM 模型在药桑叶片分类实验中对测试集的预测性能最优, R^2 均达到 0.954。混淆矩阵分析显示, 健康叶片、虫害叶片、遮阴叶片在两个不同模型中均取得了相同的分类准确率, 结果分别为 96%、93% 和 98%, 营养缺失叶片在两个模型中的准确率分别为 96% 和 97%。在叶绿素含量预测中, 采用 RD 结合基线校正(Baseline Correction, BC)进行样本集划分的偏最小二乘(Partial Least Squares, PLS)模型(RD-BC-PLS)表现最优, 在测试集上的 R^2 为 0.895, 均方根误差(Root Mean Square Error, RMSE)为 3.461, 且权重分析筛选出 505 nm 和 734 nm 为叶绿素含量预测关键波长。以 505 nm 和 734 nm 为参数提出新的光谱指数, 与 19 种传统植被指数对比发现, 红边归一化植被指数(Red Edge Normalized Vegetation Index, NDVI705)与新指数 MFD734-505 的叶绿素预测效果相当, 在测试集上的 R^2 均为 0.864。本模型系统为药桑工厂化种植的精准监测与智慧管理奠定了重要基础。

关键词: 药桑; 高光谱; 分类模型; 叶绿素含量; 回归模型

中图分类号: S88; TP181

文献标识码: A

文章编号: 1673-9868(2026)02-0001-16

开放科学(资源服务)标识码(OSID):



Classification of Medicinal Mulberry Leaf and Prediction of Chlorophyll Content

LUO Yiwei, LIU Hongjiang, LI Wei,
LI Li, YUAN Jianglian, HE Ningjia

State Key Laboratory of Resource Insects, Southwest University, Chongqing 400716, China

Abstract: To advance the construction of a factory-based precision management system for medicinal

收稿日期: 2025-04-25

基金项目: 国家重点研发计划项目(2024YFD2201302); 西南大学创新研究 2035 先导计划(SWU-XDZD22008); 中央高校基本科研业务费(SWU-KF25033)。

作者简介: 罗义维, 博士, 高级实验师, 主要从事桑树表型组研究。

通信作者: 何宁佳, 博士, 教授。

mulberry, this study first established hyperspectral reflectance-based classification models for leaves under distinct physiological conditions. Subsequently, chlorophyll content prediction models were developed. During the model construction, 3 sample set division methods, 5 data preprocessing methods, and 5 machine learning algorithms were systematically compared. Results of medicinal mulberry leaf classification indicated that the support vector machine (SVM) models using random database (RD) with either raw data or multiplicative scatter correction (MSC) for sample partitioning-specifically, the RD-RAW-SVM and RD-MSC-SVM-achieved the best R^2 values of 0.954 on the test set. Confusion matrix analysis revealed that the classification accuracies for healthy, infested, and shaded leaves were identical across the two different models, yielding 96%, 93%, and 98%, respectively. Nutrient-deficient leaves correctly classified with accuracies of 96% and 97% in the two models. For chlorophyll content prediction, the partial least squares (PLS) model using RD combined with baseline correction (BC)-specifically, RD-BC-PLS-demonstrated optimal performance, with a testing set R^2 of 0.895 and root mean square error (RMSE) of 3.461. Additionally, weight analysis identified two critical wavelengths (505 nm and 734 nm) contributing maximally to chlorophyll content prediction, enabling the derivation of novel spectral indices. Comparative evaluation with 19 conventional vegetation indices revealed that the red-edge normalized difference vegetation index (NDVI705) and the newly developed MFD734-505 exhibited equivalent predictive efficacy for chlorophyll estimation, with a testing set R^2 of 0.864. This integrated modeling framework provides an important foundation for the precise monitoring and intelligent management of factory-based medicinal mulberry cultivation.

Key words: medicinal mulberry; hyperspectral reflectance; classification model; chlorophyll content; regression model

桑树作为古代丝绸之路的重要基石,数千年来在蚕桑业和传统医药中具有不可替代的地位,《本草纲目》对此早有记载。研究表明,桑树在治疗肥胖^[1-2]、高血压^[3]和糖尿病^[4]等方面具有重要的药理活性。其中最突出的是药桑(*Morus nigra* L.)。该品种原产伊朗,广泛种植于中国新疆地区,具有特殊遗传结构(22倍体, $2n=308$)和丰富的次生代谢产物^[5-6]。当前,药桑以无性繁殖为主,新疆地区主要采用嫁接育苗,然而该方法存在成活率低、出圃率低、建园缓慢的缺陷^[7]。此外,药桑可通过组织培养快速获得大量幼苗,但组培苗在户外栽培易受病虫害侵害^[8],且环境因素会显著影响次生代谢物积累^[9]。因此,创新药桑栽培模式,实现标准化精准化生产至关重要。

植物工厂通过精准的环境调控可实现周年生产,提升生物量^[10],此外,该技术能加速种苗繁育、缩短生产周期并保障苗木质量的一致性,为规模化种植和产业化发展提供支撑^[11]。植物工厂目前已经用于多种高价值药用植物^[12-13],如蛇根草(*Ophiorrhiza pumila*)的快速繁育与植物化学物质均一化生产^[14]。该方法为药桑产业化提供了坚实的技术支撑。然而,要实现高效的规模化生产,仍需引入智能化的精准监测系统作为支撑。

高光谱技术通过多波段反射光谱捕捉植物精细特征^[15]。现代农业系统正广泛集成高光谱传感器,用于胁迫表型分类^[16-17]和化合物含量分析^[18-19]。此外,高光谱数据可开发波段筛选模型,创建具有更强预测能力的新指数^[20],这些指数在现代农事管理中对各类农业指标的预测至关重要^[21]。随着计算机领域的发展,基于机器学习的预测模型能够精准捕捉叶绿素动态对虫害胁迫、遮光胁迫及营养缺失胁迫的敏感性响应特

征^[22-23], 从而为作物健康状态的动态监测提供关键依据。

本研究聚焦于药桑组培苗的室内工厂化生产场景, 通过施加不同处理方式, 采集高光谱反射率数据。首先, 运用 5 种预处理方法, 基于极限学习机(Extreme Learning Machine, ELM)、支持向量机(Support Vector Machine, SVM)、K 近邻(K-Nearest Neighbors, KNN)、偏最小二乘(Partial Least Squares, PLS)和随机森林(Random Forest, RF)这 5 种算法, 开发叶片不同生理状态的分类模型。针对叶绿素含量的预测, 采用 ELM、多元线性回归(Multiple Linear Regression, MLR)、支持向量回归(Support Vector Regression, SVR)、PLS 和 RF 方法构建回归模型, 进一步从高光谱数据中筛选出特征波段, 构建新的植被指数, 并与传统植被指数在叶绿素含量预测性能方面进行比较分析。通过分类模型与回归模型的联合运用, 能够同步检测药桑组培苗的胁迫状态(如虫害、遮光、营养)和生理状态(如叶绿素含量水平), 从而为药桑的产业化栽培管理提供坚实的数据支撑。

1 材料和方法

1.1 药桑的室内栽培与实验处理

药桑植株在西南大学国家桑树品种改良中心(重庆分中心)的室内环境中培育。生长参数设定为 25 ± 3 °C、50%相对湿度及 16 h 光照/8 h 黑暗循环, 光源为 LED。药桑栽培于 28 cm×25 cm 盆中, 基质为营养土、珍珠岩与蛭石混合(体积比 16:1:1)。每组处理持续 4 周, 每周浇水 1 次, 每两周施用平衡型水溶肥, 施肥方案参照厂商说明。自然虫害以白粉虱侵染为主; 遮光处理采用 90%以上遮光率, 其他条件不变; 营养缺陷组仅浇水不施肥。

1.2 叶绿素含量测定

针对不同处理组的药桑叶片, 随机选取完全展开的叶片, 使用 SPAD-502 叶绿素仪进行无损检测^[24]。在叶片尖端预设 a、b、c 3 个位点作为感兴趣区域(ROI, 图 1), 每个点位重复测量 3 次, 取均值作为该点的 SPAD 值。剔除测量误差导致的异常值后, 最终获得 1 238 组数据, 其中健康叶 525 组、虫害叶 431 组、遮光叶 228 组和营养缺陷叶 54 组。



点 a、b 和 c 代表每片叶子的 SPAD 值的 3 个测量点。

图 1 数据采集示意图

1.3 光谱数据采集与预处理

通过轨道式高通量植物表型平台(PhenoWatch, 泽泉科技, 上海)采集上述测定了叶绿素含量的叶片的 RGB 和高光谱成像数据。轨道式高通量表型平台集成 Dualix 高光谱模块(双利合谱, 江苏)和 RGB 模块(MV-CS200-10GC, 海康, 浙江), RGB 模块的分辨率为 2000 万像素。高光谱成像系统配备 Image- λ -V10-HR 光谱仪、HSIA-OL23 镜头、双 HSIA-LS-T-600W 光源, 可采集 400~1 000 nm 波段区间的 176 反射光谱。高光谱数据通过 SpectraVIEW(v2.9.2.33)软件进行黑白校正和平滑处理, 在 HyperScan 软件中选取 SPAD 仪检测的 ROI 点位反射光谱用于后续分析。

本研究采用 Savitzky-Golay 平滑(Savitzky-Golay Smoothing, SG)、最小-最大归一化(Min-Max Normalization, MMN)、标准正态变量变换(Standard Normal Variate, SNV)、多元散射校正(Multiplicative Scatter Correction, MSC)和基线校正(Baseline Correction, BC)预处理高光谱数据, 以降低基线漂移影响。此外, 采用 Kennard-Stone (KS)、基于联合 X-Y 距离的样本集划分(Sample Set Partitioning Based on Joint X-Y Distances, SPXY)和随机数据集(Random Database, RD), 按 3:1 比例划分训练集与测试集, 确保光谱代表性。分类模型中, 为了消除样本量不平衡, 采用高斯噪声对最小样本营养缺陷叶数据进行增强, 每个样本生成 3 个增强样本。

1.4 分类与回归模型构建及评估

基于 Python 的 Scikit-learn 库开发机器学习模型, 重点构建药桑叶片 4 分类(健康、虫害、遮光和营养缺陷)模型及不同处理下叶绿素含量回归模型。针对 400~1 000 nm 的 176 个波段, 系统整合 5 种预处理方法(MMN、SG、MSC、SNV 和 BC)与 5 种算法优化分类预测与叶绿素回归模型。为验证稳健性, 各算法迭代 100 次, 采用 100 次决定系数(Coefficient of Determination, R^2)和均方根误差(Root Mean Square Error, RMSE)的平均值评估模型性能, 混淆矩阵采用 100 次不同分类预测概率的平均值进行展示。如图 2 所示, 以全波段光谱反射率为输入, 系统应用预处理策略与算法组合建立物质特异性高光谱分析框架。通过网络搜索与 10 折交叉验证从预设参数空间确定最优超参数。

1.5 叶绿素光谱指数开发

研究者采用光谱反射率一阶导数估算叶绿素^[25]。本研究通过光谱特征分析确定两个关键波段组合: 第一组基于光谱相关性分析确定的吸收谷(551 nm 与 709 nm), 第二组为叶绿素预测模型中权重最大的最优波段(505 nm 与 734 nm)。利用每组波段的一阶导数反射率, 通过差值、比值和归一化等方法构建新指数(表 1)。为评估新指数性能, 系统性比较了 19 种文献报道的指数(数学公式与参考文献见表 2)。

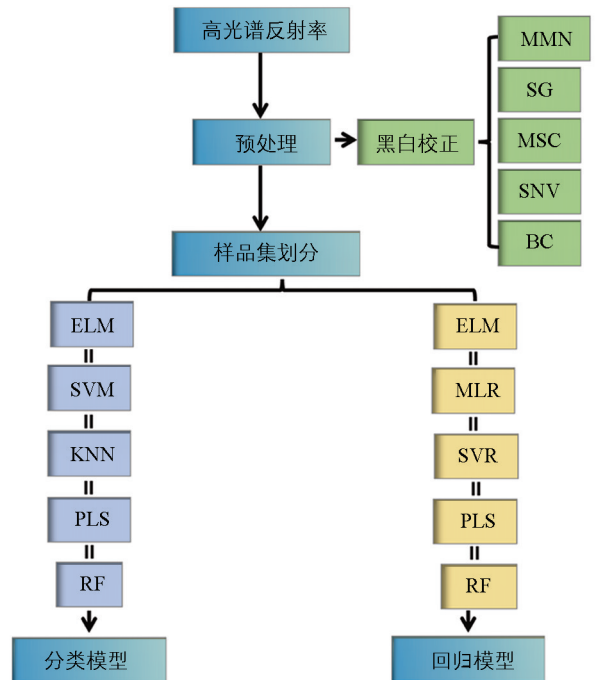


图 2 构建分类模型和叶绿素含量回归模型的工作流程示意图

表 1 基于一阶导数光谱的高光谱指数

| 指数 | 定义 |
|--------------------------|---------------------------------|
| MFD551 | 光谱在 551 nm 处的一阶导数值。 |
| MFD709 | 光谱在 709 nm 处的一阶导数值。 |
| MFD709-551 | 光谱在 709 nm 和 551 nm 处一阶导数的差值。 |
| MFD709/551 | 光谱在 709 nm 和 551 nm 处一阶导数的比值。 |
| $MFD(709-551)/(709+551)$ | 光谱在 709 nm 和 551 nm 处一阶导数的归一化值。 |
| MFD505 | 光谱在 505 nm 处的一阶导数值。 |
| MFD734 | 光谱在 734 nm 处的一阶导数值。 |
| MFD734-505 | 光谱在 734 nm 和 505 nm 处一阶导数的差值。 |
| MFD734/505 | 光谱在 734 nm 和 505 nm 处一阶导数的比值。 |
| $MFD(734-505)/(734+505)$ | 光谱在 734 nm 和 505 nm 处一阶导数的归一化值。 |

注: MFD 表示桑树一阶导数(Mulberry First Derivative)。

表 2 用于估算药桑叶的叶绿素含量的植被指数

| 指数 | 公式 | 参考文献 |
|------------------------|---|------|
| 归一化植被指数(NVI) | $(\rho_{800}-\rho_{680})/(\rho_{800}+\rho_{680})$ | [26] |
| 比值植被指数(RVI) | ρ_{800}/ρ_{680} | [27] |
| 增强型植被指数(EVI) | $2.5 * (\rho_{800}-\rho_{680})/(\rho_{800}+6 * \rho_{680}-7.5 * \rho_{450}+1)$ | [28] |
| 大气阻抗植被指数(ARVI) | $(\rho_{800}-(2 * \rho_{680}-\rho_{450})) / (\rho_{800}+(2 * \rho_{680}-\rho_{450}))$ | [29] |
| 红边归一化植被指数(NDVI705) | $(\rho_{750}-\rho_{705})/(\rho_{750}+\rho_{705})$ | [30] |
| 改进的红边比值植被指数(mSR705) | $(\rho_{750}-\rho_{445})/(\rho_{705}+\rho_{445})$ | [30] |
| 改进的红边归一化植被指数(mNDVI705) | $(\rho_{750}-\rho_{705})/(\rho_{705}+\rho_{705}-2 * \rho_{445})$ | [30] |
| 沃格尔曼红边指数 1(VOG1) | ρ_{740}/ρ_{720} | [31] |
| 沃格尔曼红边指数 2(VOG2) | $(\rho_{734}-\rho_{747})/(\rho_{715}+\rho_{726})$ | [31] |
| 沃格尔曼红边指数 3(VOG3) | $(\rho_{734}-\rho_{747})/(\rho_{715}+\rho_{720})$ | [31] |
| 光化学反射指数(PRI) | $(\rho_{531}-\rho_{570})/(\rho_{531}+\rho_{570})$ | [32] |
| 结构不敏感色素指数(SIPI) | $(\rho_{800}-\rho_{445})/(\rho_{800}+\rho_{680})$ | [33] |
| 类胡萝卜素反射指数 1(CRI1) | $1/\rho_{510}-1/\rho_{550}$ | [33] |
| 类胡萝卜素反射指数 2(CRI2) | $1/\rho_{510}-1/\rho_{700}$ | [33] |
| 花青素反射指数 1(ARI1) | $1/\rho_{550}-1/\rho_{700}$ | [33] |
| 花青素反射指数 2(ARI2) | $\rho_{800} * (1/\rho_{550}-1/\rho_{700})$ | [33] |
| 水分波段指数(WBI) | ρ_{900}/ρ_{970} | [34] |
| 植被衰败指数(PSRI) | $(\rho_{680}-\rho_{500})/\rho_{750}$ | [35] |
| 土壤调节植被指数(SAVI) | $((\rho_{800}-\rho_{680})/(\rho_{800}+\rho_{680}+0.5)) * (1+0.5)$ | [36] |

注: “ ρ 波长数值”表示该波长处的光谱反射率的值。

1.6 软件与统计分析

采用 SPSS 19 进行统计分析与相关性研究, Duncan 检验比较均值(显著性阈值 $p \leq 0.05$), 组间差异通过单因素方差分析(ANOVA)评估。Python 3.12 用于模型构建、线性回归及大数据折线图生成。

2 结果与分析

2.1 不同处理条件下叶片的全波段反射特性

图 3 展示了不同处理条件下药桑叶的高光谱变化。所有光谱曲线在 550 nm 和 740 nm 处均呈现出明显的吸收特征。在 450 nm(蓝光区域)和 650 nm(红光区域)之间出现一个显著的反射峰,该反射峰位于 550 nm(绿光区域)。在可见光光谱(500~750 nm)范围内,与健康叶片相比,受虫害叶片、遮阴叶片和营养缺陷叶片的反射率显著降低。所有的光谱在近红外范围(700~900 nm)内发生明显的变化。在近红外光谱(750~1 000 nm)范围内,营养缺陷叶片的近红外反射率明显较低,而受虫害叶片、遮阴叶片与健康叶片的反射率差异不显著。


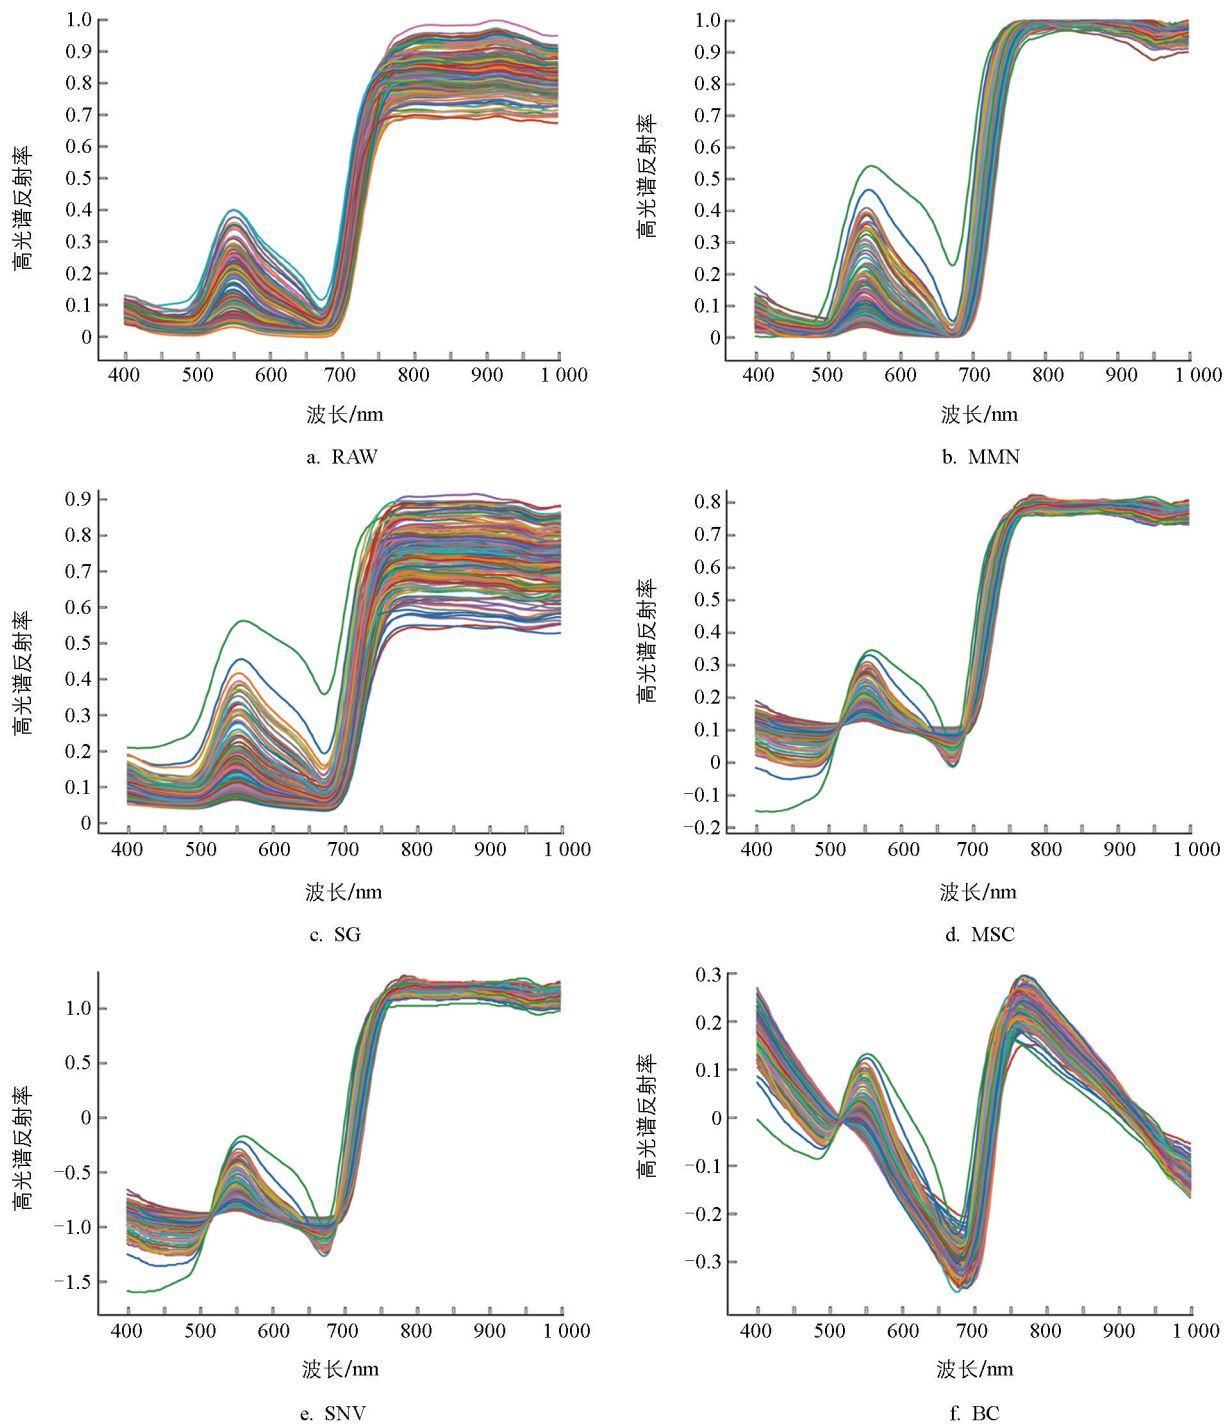


图 3 健康、虫害、遮阴和营养缺陷药桑叶片及其高光谱反射率

2.2 光谱数据预处理和分类方法

为了提高检测模型的预测准确性和稳定性,系统地应用了 5 种预处理策略(图 4)。原始光谱(RAW)是通过 SpectraVIEW 光谱分析软件从药桑叶的高光谱图像中提取的未经处理的吸收数据。与原始光谱相比,MMN 和 SG 预处理在可见光范围(400~700 nm)内表现出更强的振幅变化。在近红外区域(750~1 000 nm),MMN 处理导致光谱收缩,而 SG 处理则产生了更大的振幅变化。经过 MSC 和 SNV 预处理后,光谱范围在 500~1 000 nm 区域内显著收缩,有效减轻了散射引起的光谱变化,同时纠正了光谱数据中的基线漂移和偏移。MMN、MSC、SNV 和 BC 预处理均有效地增强了 750 nm 以上区域的光谱收敛性,产生了重叠的光谱轨迹,变异性降低。相反,SG 处理放大了 750~1 000 nm 关键波段内的信号分辨率。

样本划分对模型的稳健性影响较大。如图 5 所示,KS 和 SPXY 优先选择了 550 nm 处反射率更低且 750~1 000 nm 区间内反射率高的样本,而 RD 的选择则相对均匀。采用这 3 种不同的样本划分方法构建了对比模型,结果显示,采用 RD 方法建立的模型,在 R^2 和 RMSE 两项指标上均优于 KS 和 SPXY 方法,因此选择 RD 方法进行后续分析。为了减轻大规模数据集($n=1\ 239$)中的随机抽样误差,进行 100 次迭代取平均值。




横轴为波长, 纵轴为光谱反射率。

图 4 采用 MMN、SG、MSC、SNV 和 BC 对药桑叶光谱反射率数据预处理

2.3 不同处理材料分类模型的构建

分类模型在不同预处理方法和算法下的性能差异显著(表 3)。与原始数据相比, 在 KNN 和 RF 算法下, 预处理方法均显著提升了测试集的 R^2 值。MSC 预处理显著提升了 ELM 算法测试集的准确率。然而, ELM、SVM 和 PLS 模型在使用数据预处理后出现 R^2 显著降低, 表明在这些预处理后, 光谱特征发生了退化。此外, KNN、PLS 和 RF 算法中训练集和测试集之间的差异较大, 出现了明显的算法过拟合现象。值得注意的是, 相较于其他算法组合, SVM 算法无论是在原始数据还是在 MSC 光谱预处理条件下均表现出更优的预测准确性。具体而言, RD-RAW-SVM 与 RD-MSC-SVM 模型展现出更强的稳健性, 其在训练集上的 R^2 值分别为 0.975 ± 0.008 和 0.976 ± 0.008 , 在对应测试集上的 R^2 值则分别为 0.954 ± 0.011 和



蓝线代表训练集, 绿线代表测试集。横轴为波长, 纵轴为光谱反射率。


图 5 不同样本划分方法对比

0.954±0.009。混淆矩阵分析结果(图 6)显示, RD-RAW-SVM 和 RD-MS-C-SVM 模型对 420 个测试集样本(健康: 158 个; 虫害: 129 个; 遮阴: 69 个; 营养缺陷: 64 个)的 4 种叶片状况进行了预测, 健康叶片(96%)、受虫害叶片(92%)、遮阴叶片(99%)和营养缺陷样本(96%和 97%)的预测准确率均较高。

表 3 不同预处理方法和算法下, 药桑叶光谱反射率分类检测模型的 R^2 值

| 算法 | 集合 | RAW | MMN | SG | MSC | SNV | BC |
|-----|-----|---------------|----------------|---------------|---------------|----------------|---------------|
| ELM | 训练集 | 0.931±0.010a | 0.931±0.009a | 0.928±0.009a | 0.929±0.011a | 0.929±0.009a | 0.893±0.018b |
| | 测试集 | 0.904±0.015a | 0.902±0.014a | 0.900±0.015ab | 0.903±0.014a | 0.897±0.015b | 0.855±0.020c |
| SVM | 训练集 | 0.975±0.008a | 0.976±0.008a | 0.976±0.008a | 0.976±0.008a | 0.976±0.008a | 0.961±0.004b |
| | 测试集 | 0.954±0.011a | 0.950±0.010b | 0.952±0.009ab | 0.954±0.009a | 0.951±0.009ab | 0.937±0.009c |
| KNN | 训练集 | 1.000±0.000a | 1.000±0.000a | 1.000±0.000a | 0.995±0.023b | 0.998±0.014ab | 0.997±0.016ab |
| | 测试集 | 0.836±0.013bc | 0.833±0.013 cd | 0.837±0.014b | 0.830±0.015d | 0.833±0.014bed | 0.854±0.014a |
| PLS | 训练集 | 0.904±0.006a | 0.901±0.006c | 0.903±0.006ab | 0.902±0.005bc | 0.901±0.006c | 0.902±0.006bc |
| | 测试集 | 0.823±0.012a | 0.820±0.012a | 0.815±0.014b | 0.816±0.014b | 0.812±0.016b | 0.822±0.016a |
| RF | 训练集 | 0.999±0.002a | 0.999±0.002a | 0.999±0.001a | 0.999±0.002a | 0.999±0.001a | 0.999±0.002a |
| | 测试集 | 0.916±0.015b | 0.918±0.013ab | 0.915±0.013b | 0.922±0.013a | 0.916±0.016b | 0.916±0.014b |

注: 数据为平均值±标准差。同行不同字母表示经 Duncan 检验均值差异显著($p \leq 0.05$)。



数字 1—4 分别表示健康组、虫害组、遮阴组和营养缺陷。颜色梯度表示标准化预测概率。

图 6 RD-RAW-SVM 和 RD-MS-C-SVM 模型对不同处理材料的混淆矩阵


2.4 基于高光谱反射分析的叶绿素含量预测

图 7 展示了 176 个波段(400~1 000 nm)与叶绿素相对含量(SPAD 值)之间的相关性。光谱反射率与叶绿素含量在 400~780 nm 区间内呈负相关,而在 780~1 000 nm 区域内为正相关。具有显著相关性($|r| > 0.4$, $p \leq 0.05$)的波段主要集中在 400~750 nm 之间。光谱轮廓显示两个明显的低谷,其中最小值分别位于 551 nm 和 709 nm。

如表 4 所示,除了 MLR 和 PLF 算法,其他算法在预处理后均不同程度地提升了测试

集的 R^2 。RD-SNV-RF 模型在训练集($R^2 = 0.977$)和测试集($R^2 = 0.902$)之间的性能存在显著差异,这表明可能存在过拟合风险。因此,模型优化优先考虑训练集和测试集的平衡性和最大的测试性能。综合评估,RD-BC-PLS 模型在训练集和测试集上的 R^2 值相当,分别为 0.898 ± 0.004 和 0.895 ± 0.008 ,相比之下,该模型具有较高的预测性能,因此,选择 RD-BC-PLS 为最优模型。图 8a 展示了测试集的线性回归方程为 $y = 0.91x + 3.39$ 。对建模过程中各波长的平均权重值进行分析(图 8b),结果显示 505 nm 和 734 nm 两个波段的平均权重值大于 12,为预测的关键光谱波段。

随后,采用 RD-BC-PLS 模型对药桑完整植株(图 9a)和离体叶片(图 9b)的叶绿素含量进行像素级量化,从而生成高分辨率的叶绿素分布图。整株药桑中,顶端叶片及枝条的叶绿素含量较低。随着叶片成熟度增加,叶绿素含量逐渐增加;随着叶片逐渐衰老,叶片叶绿素含量逐渐降低。离体叶片(图 9c)中,同一



横轴表示波长,纵轴表示相关系数。


图 7 不同波长反射率与叶绿素含量之间的相关性

张叶片的不同像素点的叶绿素含量同样存在差异。该方法成功捕捉了不同叶片材料和整个植株系统中叶绿素的动态响应模式,从而建立了一种用于空间叶绿素含量评估的可视化无损方法。

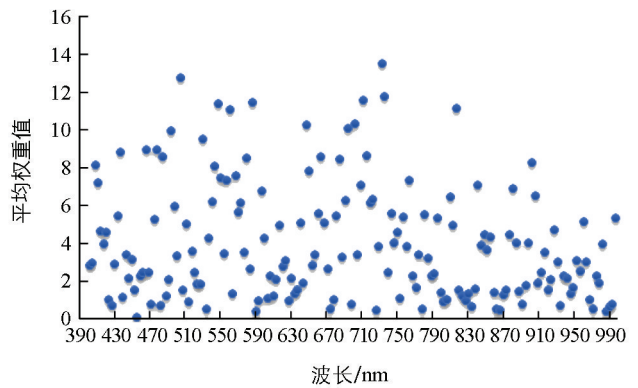
表 4 不同预处理方法与算法下基于药桑叶光谱反射率的不同处理组叶绿素含量预测模型 R^2 值

| 算法 | 集合 | RAW | MMN | SG | MSC | SNV | BC |
|-----|-----|----------------|--------------|---------------|---------------|---------------|---------------|
| ELM | 训练集 | 0.908±0.007b | 0.904±0.006c | 0.909±0.006b | 0.912±0.006a | 0.910±0.008ab | 0.910±0.009ab |
| | 测试集 | 0.886±0.011b | 0.881±0.012c | 0.888±0.011ab | 0.891±0.010a | 0.891±0.011a | 0.890±0.011ab |
| MLR | 训练集 | 0.921±0.003a | 0.920±0.003b | 0.919±0.003c | 0.917±0.003e | 0.918±0.003d | 0.918±0.003de |
| | 测试集 | 0.875±0.009a | 0.875±0.011a | 0.874±0.010a | 0.869±0.010b | 0.870±0.010b | 0.869±0.011b |
| SVR | 训练集 | 0.900±0.008c | 0.901±0.004c | 0.902±0.011c | 0.940±0.009a | 0.937±0.016a | 0.927±0.016b |
| | 测试集 | 0.892±0.009b | 0.890±0.010b | 0.891±0.012b | 0.895±0.012a | 0.898±0.010a | 0.896±0.011a |
| PLS | 训练集 | 0.896±0.004 cd | 0.895±0.003e | 0.897±0.003bc | 0.896±0.003de | 0.899±0.003a | 0.898±0.004a |
| | 测试集 | 0.893±0.008ab | 0.888±0.009c | 0.891±0.008b | 0.888±0.010c | 0.891±0.009b | 0.895±0.008a |
| RF | 训练集 | 0.973±0.013b | 0.979±0.007a | 0.971±0.013b | 0.978±0.008a | 0.977±0.007a | 0.977±0.009a |
| | 测试集 | 0.884±0.010d | 0.898±0.008b | 0.884±0.010d | 0.902±0.007a | 0.902±0.009a | 0.895±0.009c |

注:数据为平均值±标准差。同一行中不同字母表示根据邓肯氏检验(Duncan's tests)均值间存在显著差异($p \leq 0.05$)。



a. RD-BC-PLS回归模型



b. 模型中各波长的平均权重值

图 8 基于 RD-BC-PLS 构建的药桑叶叶绿素含量模型及其平均权重分析

2.5 利用优化的植被指数开发叶绿素预测模型




从关键吸收特征(551 nm 和 709 nm)和叶绿素含量预测模型中权重最高的两个波段(505 nm 和 734 nm)的光谱反射率中提取一阶微分值。通过微分、比率和归一化运算,开发了 10 个用于药桑叶绿素估算的光谱指数(表 1)。通过与 SPAD 测量值的皮尔逊相关性分析,将新植被指数与 19 个已建立的植被指数进行了比较。如图 10 所示,有 17 个强相关($|r| > 0.7$),6 个中等相关($0.4 \leq |r| \leq 0.7$),6 个弱相关($|r| < 0.4$),其中,7 个指数表现出极强的相关性($|r| > 0.9$),包括 NDVI705(0.930)、MFD734-505(0.920)、VOG1(0.911)、mNDVI705(0.909)、MFD734(0.901)、PSRI(-0.902)和



a. 盆栽药桑树



b. 不同状态的药桑叶




c. 基于RD-BC-PLS模型反演获取的药桑叶叶绿素含量可视化分布图

色块代表叶绿素含量阈值。

图 9 药桑叶叶绿素含量可视化分布图

MFD505(-0.910)。随后选取了 3 个相关系数最高的植被指数(表 5), 采用 PLS 算法进行模型预测, 结果显示, NDVI705 和 MFD734-505 的预测能力相当, 其 R^2 分别为 0.864 ± 0.012 和 0.864 ± 0.011 , 显著优于 VOG1。



* 表示在 0.01 水平上显著相关(双尾检验), ** 表示在 0.05 水平上显著相关(双尾检验)。

图 10 药桑叶不同植被指数与 SPAD 值的相关性分析

表 5 基于不同植被指数的药桑叶光谱反射率 PLS 算法 SPAD 预测模型的 R^2 与 RMSE 值

| | | NDVI705 | MFD734-505 | VOG1 |
|-----|-------|--------------|--------------|--------------|
| 训练集 | R^2 | 0.866±0.005a | 0.867±0.004a | 0.830±0.005b |
| | RMSE | 3.980±0.059b | 3.971±0.046b | 4.483±0.061a |
| 测试集 | R^2 | 0.864±0.012a | 0.864±0.011a | 0.828±0.012b |
| | RMSE | 4.005±0.137b | 3.989±0.106b | 4.486±0.144a |

注: 数据为平均值±标准差。同行不同字母表示经 Duncan 检验均值间存在显著差异($p \leq 0.05$)。

3 讨论与结论

3.1 讨论

3.1.1 室内药桑的光谱及生理关系

药桑叶的高光谱特征分析为室内栽培条件下光谱与生理间的关系提供了重要信息。首先,在可见光光谱(400~750 nm)范围内,观察到了健康植被典型的 3 峰反射模式,其吸收谷分别位于 450 nm(蓝光)和 650 nm(红光),两者间是 550 nm 处的绿色反射峰(图 3)。这一模式可作为评估叶绿素活性的可靠基线^[37]。然而,受胁迫的叶片呈现出差异特征,与健康对照相比,在 500~750 nm 范围内的光谱反射率增加,但不同胁迫类型呈现出不同的特征模式。在 500~750 nm 范围内,受虫害叶片光谱反射率高于健康叶片光谱反射率,这一发现与已有文献报道的研究结果一致^[38-39]。田间研究报告在遮阴条件下,与正常生长的叶片相比,在 500~750 nm 区间植物叶片的光谱反射率会降低^[40-41],但本研究在室内栽培条件下,光谱反射率出现相反的模式,表明自然遮阴和可控光照环境之间存在显著的生理差异。造成这一差异可能的原因是,本研究中使用的人工照明系统添加了红光(600~700 nm)和蓝光(400~500 nm)光谱带,研究表明,这些波段与叶绿素生物合成和养分吸收有关^[42-43]。此外,研究表明,在 500~750 nm 范围内,光谱反射率与叶片养分含量之间呈反比关系^[44-45],这一结果与本研究结果相符,进一步证实了光谱反射率模式与植物生理状态之间的直接相关性。在近红外过渡区(750~1 000 nm),叶片呈现出预期的反射率快速增加随后趋于平稳的现象^[44],而营养缺陷样本与其他胁迫组相比,近红外反射率显著降低。由于近红外反射率主要取决于叶片内部结构^[46],这表明养分缺乏比生物胁迫或光照限制引起的超微结构变化更为显著。本研究为室内药桑生产中的早期营养缺陷检测提供了潜在的光谱标记。

3.1.2 机器学习模型的性能与优化

本研究基于 RAW 或 MSC 预处理,采用 SVM 算法构建的模型,在健康、虫害、遮阴和营养缺陷叶片的分类准确率超过 92%,展示了较高的预测性能。原始数据中,营养缺陷叶片采集较少,为了消除模型评估指标失真和评估偏移,采用高斯噪声的方法进行 3 倍数据增强,与未增强时的预测性能相比,极大提升了营养缺陷叶片的预测性能(数据未展示,提升了 10%)。

现有研究中,通过计算机算法预测叶绿素含量的数据来源主要包括 RGB 图像和高光谱反射率等。玉米中的研究表明,在温室条件下,基于 RGB 图像特征的模型对叶绿素含量的预测 R^2 为 0.67~0.88^[47]。在可控光照条件下,基于 RGB 颜色特征的像素级叶绿素含量的预测 R^2 可达到 0.97^[48]。本研究采用高光谱反射率数据对药桑叶片叶绿素含量进行预测,预测性能与相关研究对多年生作物的预测性能相当,如枣树的 R^2 为 0.89^[49]。

植被指数,尤其是红边归一化植被指数(NDVI),是评估植物生理动态的基本诊断工具^[50]。NDVI705 与枣树^[51]和生菜^[47]的叶绿素含量显示出更优的相关性,这与我们的实验结果相符。值得注意的是,我们通过模型构建筛选出的波长建立的指数 MFD734-505,展现出与 NDVI705 相当的预测能力。MFD734-505 通

过 734 nm 和 505 nm 的一阶导数差值构建, 505 nm 波段位于叶绿素 b 的最大吸收峰(450~500 nm)附近, 通过其对色素浓度和栅栏组织结构的双重响应, 可作为早期胁迫检测的敏感生物传感器^[30,37], 734 nm 波长位于叶绿素敏感的红边过渡区(700~750 nm), 其导数反映叶绿素含量变化引起的红边位移, 该区域的反射率梯度与由叶肉结构介导的叶绿体分布模式相关^[52-53]。734 nm 和 505 nm 的一阶导数差值可用于增强叶绿素信号并抑制背景干扰, 从而更灵敏地捕捉叶绿素动态。本研究中, 该指数能够有效应用于处于不同胁迫条件下且叶绿素含量差异显著的药桑样本的叶绿素含量预测。在后续研究中, 可探索不同的光谱特征和先进算法, 以进一步提高模型在不同生长条件和品种中的泛化能力。

3.1.3 药桑精准栽培的实际应用与未来展望

本研究基于高光谱成像技术开发了药桑叶分类模型和叶绿素含量预测模型, 借助该模型, 可实现对药桑生理状态的实时、无损评估, 包括早期检测生物和非生物胁迫、优化施肥和灌溉方案, 以及通过叶绿素定量进行持续质量监测。这一方案可为现代精准农业提供关键数据支持, 直接有助于改善作物管理实践和产量优化^[37]。本研究建立的方法学框架具有跨领域应用潜力, 可进一步拓展至多个领域, 如植物或其他样品的活性成分快速无损检测^[54-55], 以及病虫害侵染早期特征的光谱识别^[56]等领域。

为了更好地服务于精准农业实践, 未来还需要对该方案不断进行完善。首先, 在数据层面, 应系统性地扩充训练数据集, 纳入更广泛的环境变异(如不同气候带、土壤类型)和连续胁迫梯度(如水分/养分亏缺程度), 从而显著提升模型的泛化能力和实际适用性。其次, 在硬件集成方面, 需与新一代微型化、低成本的光谱传感设备相结合, 特别是开发适合田间大规模部署的便携式系统, 这将直接决定技术推广的可行性。例如, 基于上述药桑叶片的高光谱反射率与机器学习算法的多模型体系, 为实现工程化应用, 后期可采用低成本多光谱传感器或便携式光谱仪替代高光谱设备, 通过嵌入式系统, 通过轻量化模型部署实现实时监测, 具体部署逻辑为: 传感器采集→边缘计算(剔除异常值)→模型推理→结果无线传输至云平台进行可视化。此外, 在技术创新层面, 后续工作应重点突破算法瓶颈, 通过融合深度学习和物理机理的混合建模策略来优化预测性能。这些技术突破将最终融入智慧农业, 为药桑产业的提质增效和可持续发展提供科技支撑。

3.2 结论

本研究构建了一个药桑精准栽培的工业化繁育框架, 将高光谱反射率分析技术与机器学习架构相结合。开发出了不同生理状态药桑叶片的分类模型, 其对健康、虫害、遮阴和营养缺陷叶片的诊断准确率均超过 90%。此外, 构建了不同生理状态药桑的叶绿素回归模型, 该模型预测性能良好(测试集 R^2 为 0.895, RMSE 为 3.461)。光谱敏感性分析确定了两个对叶绿素动态变化起关键诊断作用的关键波长(505 nm 和 734 nm), 构建了新型的 MFD734-505 植被指数。在叶绿素定量方面, 该植被指数的预测性能与 NDVI705 具有等效性($p \leq 0.05$)。本研究将高光谱传感技术与机器学习相结合, 开发药桑叶分类模型和叶绿素含量回归模型, 为药桑栽培的智能化管理提供了重要数据。

参考文献:

- [1] OH K S, YONG R, LEE S, et al. Melanin-Concentrating Hormone-1 Receptor Antagonism and Anti-Obesity Effects of Ethanolic Extract from Morus Alba Leaves in Diet-Induced Obese Mice [J]. *Journal of Ethnopharmacology*, 2009, 122(2): 216-220.
- [2] ZHAO T T, CHEN Q R, CHEN Z, et al. Anti-Obesity Effects of Mulberry Leaf Extracts on Female High-Fat Diet-Induced Obesity: Modulation of White Adipose Tissue, Gut Microbiota, and Metabolic Markers [J]. *Food Research International*, 2024, 177: 113875.
- [3] NAOWABOOT J, PANNANGPETCH P, KUKONGVIRIYAPAN V, et al. Mulberry Leaf Extract Restores Arterial Pressure in Streptozotocin-Induced Chronic Diabetic Rats [J]. *Nutrition Research*, 2009, 29(8): 602-608.

- [4] LV Q Y, LIN J R, WU X Y, et al. Novel Active Compounds and the Anti-Diabetic Mechanism of Mulberry Leaves [J]. *Frontiers in Pharmacology*, 2022, 13: 986931.
- [5] JIANG Y, NIE W J. Chemical Properties in Fruits of Mulberry Species from the Xinjiang Province of China [J]. *Food Chemistry*, 2015, 174: 460-466.
- [6] KRUTHIKA H S, RUKMANGADA M S, NAIK V G. Genome Size, Chromosome Number Variation and Its Correlation with Stomatal Characters for Assessment of Ploidy Levels in a Core Subset of Mulberry (*Morus SPP.*) Germplasm [J]. *Gene*, 2023, 881: 147637.
- [7] 吴曙光, 印玉萍, 丁天龙, 等. 新疆药桑芽接育苗技术探讨 [J]. *北方蚕业*, 2011, 32(3): 45-46.
- [8] 曾其伟, 张超, 陈鸿宇, 等. 药桑 *Morus nigra* 在重庆的引种研究 [J]. *中国中药杂志*, 2016, 41(8): 1450-1455.
- [9] LI Y Q, KONG D X, FU Y, et al. The Effect of Developmental and Environmental Factors on Secondary Metabolites in Medicinal Plants [J]. *Plant Physiology and Biochemistry*, 2020, 148: 80-89.
- [10] MIYAGI A, UCHIMIYA H, KAWAI-YAMADA M. Synergistic Effects of Light Quality, Carbon Dioxide and Nutrients on Metabolite Compositions of Head Lettuce under Artificial Growth Conditions Mimicking a Plant Factory [J]. *Food Chemistry*, 2017, 218: 561-568.
- [11] LIU Y, MOUSAVI S, PANG Z, et al. Plant Factory: A New Playground of Industrial Communication and Computing [J]. *Sensors (Basel)*, 2021, 22(1): 147.
- [12] CHO K M, LEE H Y, CHO D Y, et al. Comprehensive Comparison of Chemical Composition and Antioxidant Activity of Panax Ginseng Sprouts by Different Cultivation Systems in a Plant Factory [J]. *Plants*, 2022, 11(14): 1818.
- [13] KIM S H, PARK J H, KIM E J, et al. White LED Lighting Increases the Root Productivity of Panax Ginseng C. A. Meyer in a Hydroponic Cultivation System of a Plant Factory [J]. *Biology*, 2023, 12(8): 1052.
- [14] LEE J Y, GOTO E, YOSHIDA H, et al. Optimal Harvest-Time to Maximize the Annual Camptothecin Production by *Ophiorrhiza Pumila* in a Plant Factory with Artificial Light [J]. *Journal of Natural Medicines*, 2022, 76(4): 865-872.
- [15] LIU B, LI R, LI H D, et al. Crop/Weed Discrimination Using a Field Imaging Spectrometer System [J]. *Sensors*, 2019, 19(23): 5154.
- [16] ZHANG Q, ZHENG Y M, YUAN Q Q, et al. Hyperspectral Image Denoising: From Model-Driven, Data-Driven, to Model-Data-Driven [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(10): 13143-13163.
- [17] TIAN C X, CHEN Y Z, LIU Y L, et al. Accurate Classification of Glomerular Diseases by Hyperspectral Imaging and Transformer [J]. *Computer Methods and Programs in Biomedicine*, 2024, 254: 108285.
- [18] AGUILAR-ARIZA A, SOTTA N, FUJIWARA T, et al. A Multi-Target Regression Method to Predict Element Concentrations in Tomato Leaves Using Hyperspectral Imaging [J]. *Plant Phenomics*, 2024, 6: 146.
- [19] LONG T, TANG X Y, LIANG C J, et al. Detecting Bioactive Compound Contents in Dancong Tea Using VNIR-SWIR Hyperspectral Imaging and KRR Model with a Refined Feature Wavelength Method [J]. *Food Chemistry*, 2024, 460(Pt 2): 140579.
- [20] KOH J C O, BANERJEE B P, SPANGENBERG G, et al. Automated Hyperspectral Vegetation Index Derivation Using a Hyperparameter Optimisation Framework for High-Throughput Plant Phenotyping [J]. *The New Phytologist*, 2022, 233(6): 2659-2670.
- [21] SERRANO-GRIJALVA L, OCHOA-HUESO R, CISKA VEEN G F, et al. Normalized Difference Vegetation Index Analysis Reveals Increase of Biomass Production and Stability during the Conversion from Conventional to Organic Farming [J]. *Global Change Biology*, 2024, 30(8): e17461.
- [22] LOI M, LIUZZI V C, FANELLI F, et al. Effect of Different Light-Emitting Diode (LED) Irradiation on the Shelf Life and Phytonutrient Content of Broccoli (*Brassica Oleracea L. Var. Italica*) [J]. *Food Chemistry*, 2019, 283: 206-214.
- [23] ZIDAN K, MANDI L, HEJAJ A, et al. Soil Fertility and Agro-Physiological Responses of Maize (*Zea Mays*) Irrigated by Treated Domestic Wastewater by Hybrid Multi-Soil-Layering Technology [J]. *Journal of Environmental Management*, 2024, 351: 119802.

- [24] WANG W, CHENG Y K, REN Y, et al. Prediction of Chlorophyll Content in Multi-Temporal Winter Wheat Based on Multispectral and Machine Learning [J]. *Frontiers in Plant Science*, 2022, 13: 896408.
- [25] ZHANG Y, HAN X, YANG J. Selection of Optimal Spectral Features for Leaf Chlorophyll Content Estimation [J]. *Scientific Reports*, 2024, 14(1): 25598.
- [26] TAYLOR B F, DINI P W, KIDSON J W. Determination of Seasonal and Interannual Variation in New Zealand Pasture Growth from NOAA-7 Data [J]. *Remote Sensing of Environment*, 1985, 18(2): 177-192.
- [27] JORDAN C F. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor [J]. *Ecology*, 1969, 50(4): 663-666.
- [28] 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(1-2): 195-213.
- [29] KAUFMAN Y J, TANRE D. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1992, 30(2): 261-270.
- [30] SIMS D A, GAMON J A. Relationships between Leaf Pigment Content and Spectral Reflectance across a Wide Range of Species, Leaf Structures and Developmental Stages [J]. *Remote Sensing of Environment*, 2002, 81(2-3): 337-354.
- [31] VOGELMANN J E, ROCK B N, MOSS D M. Red Edge Spectral Measurements from Sugar Maple Leaves [J]. *International Journal of Remote Sensing*, 1993, 14(8): 1563-1575.
- [32] GAMON J A, PEÑUELAS J, FIELD C B. A Narrow-Waveband Spectral Index that Tracks Diurnal Changes in Photosynthetic Efficiency [J]. *Remote Sensing of Environment*, 1992, 41(1): 35-44.
- [33] 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.
- [34] GAO B C. NDWI—A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water from Space [J]. *Remote Sensing of Environment*, 1996, 58(3): 257-266.
- [35] MERZLYAK M N, GITELSON A A, CHIVKUNOVA O B, et al. Non-Destructive Optical Detection of Pigment Changes during Leaf Senescence and Fruit Ripening [J]. *Physiologia Plantarum*, 1999, 106(1): 135-141.
- [36] HUETE A R. A Soil-Adjusted Vegetation Index (SAVI) [J]. *Remote Sensing of Environment*, 1988, 25(3): 295-309.
- [37] GITELSON A A, GRITZ Y, MERZLYAK M N. Relationships between Leaf Chlorophyll Content and Spectral Reflectance and Algorithms for Non-Destructive Chlorophyll Assessment in Higher Plant Leaves [J]. *Journal of Plant Physiology*, 2003, 160(3): 271-282.
- [38] LIU S, YU H Y, SUI Y Y, et al. Classification of Soybean Frogeye Leaf Spot Disease Using Leaf Hyperspectral Reflectance [J]. *PLoS One*, 2021, 16(9): e0257008.
- [39] ZHANG G S, XU T Y, TIAN Y W, et al. Classification of Rice Leaf Blast Severity Using Hyperspectral Imaging [J]. *Scientific Reports*, 2022, 12: 19757.
- [40] ZHOU K, DENG X Q, YAO X, et al. Assessing the Spectral Properties of Sunlit and Shaded Components in Rice Canopies with Near-Ground Imaging Spectroscopy Data [J]. *Sensors*, 2017, 17(3): 578.
- [41] SONOBE R, HIRONO Y, OI A. Non-Destructive Detection of Tea Leaf Chlorophyll Content Using Hyperspectral Reflectance and Machine Learning Algorithms [J]. *Plants*, 2020, 9(3): 368.
- [42] BARTUCCA M L, GUIDUCCI M, FALCINELLI B, et al. Blue: Red LED Light Proportion Affects Vegetative Parameters, Pigment Content, and Oxidative Status of Einkorn (*Triticum Monococcum* L. SSP. *Monococcum*) Wheatgrass [J]. *Journal of Agricultural and Food Chemistry*, 2020, 68(33): 8757-8763.
- [43] POLA W, SUGAYA S, PHOTCHANACHAI S. Color Development and Phytochemical Changes in Mature Green Chili (*Capsicum annuum* L.) Exposed to Red and Blue Light-Emitting Diodes [J]. *Journal of Agricultural and Food Chemistry*, 2020, 68(1): 59-66.
- [44] WANG Y J, HU X, HOU Z W, et al. Discrimination of Nitrogen Fertilizer Levels of Tea Plant (*Camellia Sinensis*)

- Based on Hyperspectral Imaging [J]. *Journal of the Science of Food and Agriculture*, 2018, 98(12): 4659-4664.
- [45] OKYERE F G, CUDJOE D, SADEGHI-TEHRAN P, et al. Modeling the Spatial-Spectral Characteristics of Plants for Nutrient Status Identification Using Hyperspectral Data and Deep Learning Methods [J]. *Frontiers in Plant Science*, 2023, 14: 1209500.
- [46] ZHAI Y F, CUI L J, ZHOU X, et al. Estimation of Nitrogen, Phosphorus, and Potassium Contents in the Leaves of Different Plants Using Laboratory-Based Visible and Near-Infrared Reflectance Spectroscopy: Comparison of Partial Least-Square Regression and Support Vector Machine Regression Methods [J]. *International Journal of Remote Sensing*, 2013, 34(7): 2502-2518.
- [47] TAHA M F, MAO H P, WANG Y F, et al. High-Throughput Analysis of Leaf Chlorophyll Content in Aquaponically Grown Lettuce Using Hyperspectral Reflectance and RGB Images [J]. *Plants*, 2024, 13(3): 392.
- [48] TAN L H, ZHOU L, ZHAO N, et al. Development of a Low-Cost Portable Device for Pixel-Wise Leaf SPAD Estimation and Blade-Level SPAD Distribution Visualization Using Color Sensing [J]. *Computers and Electronics in Agriculture*, 2021, 190: 106487.
- [49] TUERXUN N, ZHENG J H, WANG R J, et al. Hyperspectral Estimation of Chlorophyll Content in Jujube Leaves: Integration of Derivative Processing Techniques and Dimensionality Reduction Algorithms [J]. *Frontiers in Plant Science*, 2023, 14: 1260772.
- [50] KHALESİ F, AHMED I, DAPONTE P, et al. The Uncertainty Assessment by the Monte Carlo Analysis of NDVI Measurements Based on Multispectral UAV Imagery [J]. *Sensors*, 2024, 24(9): 2696.
- [51] LU J Q, QIU H B, ZHANG Q, et al. Inversion of Chlorophyll Content under the Stress of Leaf Mite for Jujube Based on Model PSO-ELM Method [J]. *Frontiers in Plant Science*, 2022, 13: 1009630.
- [52] CURRAN P J. Remote Sensing of Foliar Chemistry [J]. *Remote Sensing of Environment*, 1989, 30(3): 271-278.
- [53] INOUE Y, GUÉRIF M, BARET F, et al. Simple and Robust Methods for Remote Sensing of Canopy Chlorophyll Content: A Comparative Analysis of Hyperspectral Data for Different Types of Vegetation [J]. *Plant, Cell & Environment*, 2016, 39(12): 2609-2623.
- [54] MARÍN-SAN ROMÁN S, FERNÁNDEZ-NOVALES J, CEBRIÁN-TARANCÓN C, et al. Monitorization of Varietal Aroma Composition Dynamics during Ripening in Intact *Vitis Vinifera* L. Tempranillo Blanco Berries by Hyperspectral Imaging [J]. *Journal of Agricultural and Food Chemistry*, 2023, 71(5): 2616-2627.
- [55] LI F L, SHEN J F, YANG Q F, et al. Monitoring Quality Changes in Green Tea during Storage: A Hyperspectral Imaging Method [J]. *Food Chemistry: X*, 2024, 23: 101538.
- [56] NGUYEN D H D, TAN A J H, LEE R, et al. Monitoring of Plant Diseases Caused by *Fusarium Commune* and *Rhizoctonia Solani* in Bok Choy Using Hyperspectral Remote Sensing and Machine Learning [J]. *Pest Management Science*, 2025, 81(1): 149-159.