

doi:10.6041/j.issn.1000-1298.2024.07.033

# 辣椒叶片水分胁迫高光谱特性研究

王东<sup>1,2</sup> 孙欣<sup>1,2</sup> 张岳阳<sup>1,2</sup> 夏鹤宁<sup>1,2</sup> 逯明辉<sup>3</sup> 周林凡<sup>1,2</sup>

(1. 西北农林科技大学机械与电子工程学院, 杨凌 712100; 2. 农业农村部农业物联网重点实验室, 杨凌 712100;

3. 西北农林科技大学园艺学院, 杨凌 712100)

**摘要:** 为精准判别作物需水程度, 以生长期辣椒为实验样本, 对辣椒进行不同程度的水浸、干旱等水分胁迫处理, 分析不同水分胁迫程度下辣椒叶片的高光谱响应特性。样本分为重度干旱、轻度干旱、轻度水浸、重度水浸等4个水分胁迫组和一个实验对照组, 共5个数据组, 每组20株辣椒, 待各组叶片外观出现明显差异时, 分别采集各组辣椒叶片的叶绿素荧光参数与高光谱数据。比较多元散射校正(MSC)、SG卷积平滑滤波和标准正态变换(SNV)3种不同的预处理方法对背景信息干扰的消除效果。采用SPA算法和CARS算法提取对水分胁迫敏感的特征波长。建立预测辣椒叶片不同水分胁迫程度的支持向量机(SVM)、BP神经网络、径向基函数(RBF)和随机森林(RF)模型。结果说明, SG-SPA-RFB为预测辣椒叶片水分胁迫程度的最优组合, 其训练集准确率为99.02%, 测试集准确率为94.00%。本研究为判断辣椒植株水分胁迫状态提供了一种便捷可靠的无损检测方法。

**关键词:** 辣椒; 水分胁迫; 高光谱图像; 特征波长; 神经网络; 叶绿素荧光参数

中图分类号: S2 文献标识码: A 文章编号: 1000-1298(2024)07-0336-09

OSID:

## Spectral Characteristics of Water Stress in Chili Pepper Leaves

WANG Dong<sup>1,2</sup> SUN Xin<sup>1,2</sup> ZHANG Yueyang<sup>1,2</sup> XIA Hening<sup>1,2</sup> LU Minghui<sup>3</sup> ZHOU Linfan<sup>1,2</sup>

(1. College of Mechanical and Electronic Engineering, Northwest A&amp;F University, Yangling, Shaanxi 712100, China

2. Key Laboratory of Agricultural Internet of Things, Ministry of Agriculture and Rural Affairs, Yangling, Shaanxi 712100, China

3. College of Horticulture, Northwest A&amp;F University, Yangling, Shaanxi 712100, China)

**Abstract:** In response to the need for smart agriculture to accurately discriminate the degree of crop water demand, taking growing peppers as the experimental samples, different degrees of water stress treatments such as water immersion and drought to the leaves of peppers were applied to analyze the hyperspectral response characteristics of pepper leaves under different degrees of water stress. The samples were divided into four water stress groups, including severe drought, mild drought, mild water-soaked, and severe water-soaked, and one experimental control group, with a total of five data groups of 20 chili peppers in each group, and the chlorophyll fluorescence parameters and hyperspectral data of chili peppers' leaves in each group were collected separately when the appearance of leaves in each group appeared to be obviously different. The effects of three different preprocessing methods, namely, multiplicative scatter correction (MSC), SG convolutional smoothing filter and standard normal variate transform (SNV), on the elimination of background information interference were compared. The SPA algorithm and CARS algorithm were used to extract the characteristic wavelengths sensitive to water stress. Support vector machine (SVM), BP neural network, radial basis function (RBF) and random forest (RF) modeling were established for predicting different levels of water stress. The results illustrated that SG-SPA-RFB was the optimal combination for predicting the degree of water stress with 99.02% accuracy in the training set and 94.00% accuracy in the test set. The research result can provide a convenient and reliable non-destructive method for determining the water stress status of pepper plants.

**Key words:** pepper; water stress; hyperspectral image; characteristic wavelength; neural network; chlorophyll fluorescence parameters

收稿日期: 2024-04-06 修回日期: 2024-05-06

基金项目: 国家自然科学基金项目(32172552, 31701326)

作者简介: 王东(1982—), 男, 副教授, 博士, 主要从事设施环境调控研究, E-mail: wangdong510@163.com

## 0 引言

传统判别植物水分胁迫的方法为检测土壤湿度与植物生理生化指标,但该检测方式有一定的滞后性<sup>[1]</sup>,无法用于实时决策和指导灌溉。高光谱技术以其快速、无损检测的优点被应用于检测植物的生理胁迫与生理参数。例如,ZHANG 等<sup>[2]</sup>提出了不增加计算量但提高干旱胁迫分类精度的矩阵简化法简化高光谱数据,实现了基于高光谱的番茄早期干旱胁迫检测。CHEN 等<sup>[3]</sup>利用茶叶干旱表型的高光谱图像对抗旱种质进行筛选,通过支持向量机(Support vector machines, SVM)、射频和普氏雷达对耐旱系数(DTC)数据建模,得出 DTC 模型可作为新的筛选具有抗旱性的茶叶种质资源方法。GUO 等<sup>[4]</sup>采用叶绿素荧光参数  $F_v/F_m$  检测棉花非生物植物胁迫,为解决叶绿素荧光参数  $F_v/F_m$  获取难的问题,采集不同耐旱程度棉花品种的高光谱全波段数据,建立了一维 CNN 模型。CHEN 等<sup>[5]</sup>发现发生过干旱和洪涝的土壤对植物胁迫有许多相似之处,为建立描述植物对从干旱到洪涝的反应模型提供了基础。LIN 等<sup>[6]</sup>研究了 3 个葫芦品种的生长和生理性能,发现归一化植被指数(NDVI)、光化学反射指数(PRI)与 SPAD、 $F_v/F_m$ 、量子光合产量之间显著正相关。徐鹏等<sup>[7]</sup>研究了 4 个发育阶段和 3 个涝渍深度下叶面积指数(LAI)和冠层光谱响应的变化,建立了 LAI 光谱估算模型,表明可以采用抽穗前的光谱参数估计胁迫强度。

辣椒富含人体所需的必要营养元素,是生活中重要的蔬菜与香料作物。辣椒的播种面积与产值均居我国蔬菜种植首位,且种植广泛,因此辣椒的种植环境难以达到统一<sup>[8-9]</sup>。种植范围过广致使干旱与洪涝均有可能成为影响辣椒产量的关键因素。目前虽已有部分学者对辣椒水分胁迫进行研究,但同时研究辣椒干旱与水浸判别的鲜有报道。

为研究辣椒水分胁迫的判别方法,本文将通过控制土壤含水率实现不同程度水分胁迫处理,分析不同胁迫状态下辣椒叶片的高光谱数据变化规律,研究基于高光谱技术的辣椒叶片水分胁迫程度分类模型,探寻最佳的判别辣椒生理状态下水分胁迫方法。以期为实现精准灌溉与节水灌溉实时决策提供技术支撑。

## 1 材料与方法

### 1.1 实验设计

以西北地区广泛种植的生长期辣椒“加长六号”为研究对象,2023 年 3—4 月于西北农林科技大学

学北校区园艺学院科研温室(北纬 34°15'44", 东经 108°04'03", 海拔 451 m)开展实验。由于生理参数测量需要摘取叶片,为不影响测量后辣椒长势,选取种植 50~60 d、叶片数量为 6~8、长势良好、叶片肥大、尺寸较为一致的辣椒共 100 株作为实验样本,将其种植在花盆(7 cm × 7 cm × 7 cm)中供后续使用。每 20 株幼苗分为 1 组,共分 5 组,5 组实验样本中包括 1 组对照组、2 组干旱胁迫组和 2 组水浸胁迫组。

对照组含水率控制在田间辣椒生长时土壤含水率(体积含水率 25%)的 60%~80%,为保持对照组土壤含水率不变,每天每株辣椒浇水 20 mL。干旱胁迫组将含水率控制在田间含水率的 40%~60%(轻度干旱胁迫)和 20%~40%(重度干旱胁迫)。为保持干旱胁迫组土壤含水率不变,每天每株辣椒浇适量水。为更好地控制水浸胁迫组的实验,将花盆放置在水桶中,轻度水浸胁迫组保持水面高度为花盆中土壤深度的一半,重度水浸胁迫组使水面高度保持低于土壤表面约 1 cm。为防止重度水浸胁迫组花盆受浮力作用影响实验结果,实验过程中在重度水浸胁迫组花盆中加入石块。干旱组植株胁迫处理 14 d 时,轻度干旱胁迫组辣椒叶片倾角变大,叶片出现轻度萎蔫,重度干旱胁迫组叶片下垂呈卷曲状,组间叶片外观差异明显,此时每株摘取 2~3 片叶片进行数据采集。水浸组与对照组植株胁迫处理 20 d 时,轻度水浸胁迫组辣椒叶片明显变薄,重度水浸胁迫组辣椒叶片倾角变大,部分底部叶片开始脱落,组间叶片外观差异明显,此时每株摘取 2~3 片叶片进行数据采集。不同胁迫下的叶片图像如图 1 所示。

### 1.2 数据采集

#### 1.2.1 高光谱数据采集

由于近红外光谱仪在测量光谱数据时以叶子的单点为实验样本,胁迫组的叶子不同区域光谱数据差异较大,单点数据不具有普遍性,因此选用高光谱设备采集光谱数据。用于采集高光谱数据的设备为遥感影像高精度成像系统(SOC710-VP 型,SOC,美国),波长范围 400~1 000 nm;分辨率 256;光谱响应时间约 20 ms。实验装置如图 2 所示。

为了防止一天中不同时间点辣椒生理状态差异对检测结果的影响,实验时间统一设置在 16:00—17:30,实验全程避光。实验前对仪器预热 30 min,然后将叶柄固定在载物台上进行活体测量,测量过程中载物台与镜头固定距离为 60 cm<sup>[10]</sup>。

#### 1.2.2 叶绿素荧光参数采集

使用叶绿素荧光仪(IMAGING-PAM 型,

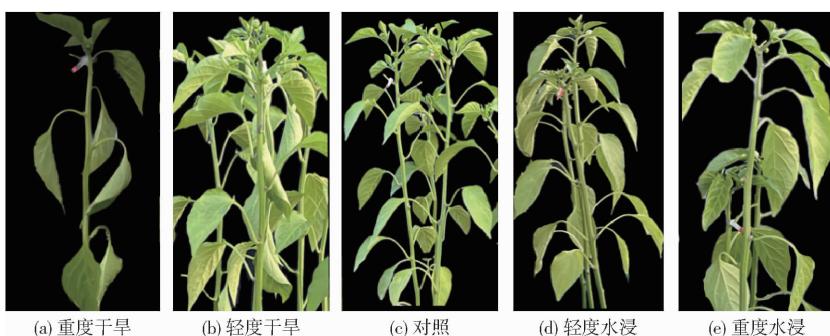


图 1 不同水分胁迫与对照组图像

Fig. 1 Pictures of different water stress and control group

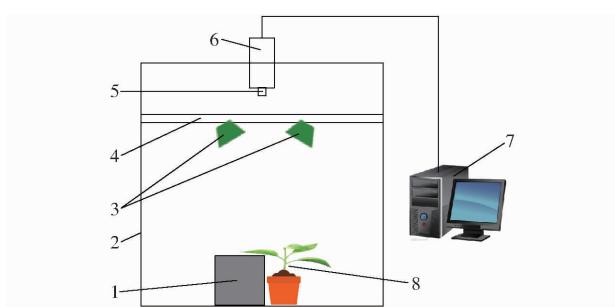


图 2 高光谱成像装置示意图

Fig. 2 Diagram of hyperspectral imaging device

1. 载物台 2. 测试架 3. 钨卤素灯光源 4. 灯架 5. 镜头 6. 高光谱成像仪 7. 数据采集计算机 8. 辣椒样本

WALZ, 德国)采集辣椒叶片的叶绿素荧光参数, 实验装置如图 3 所示。实验在暗箱环境下进行, 同时, 整个实验阶段从 19:00 开始。为保证采集结果的准确性, 在采集荧光参数前对采集完高光谱的辣椒植株进行 20 min 的暗适应<sup>[11]</sup>。暗适应结束后, 从辣椒植株上摘取用于采集完高光谱的辣椒叶片, 并将叶片展平固定在载物台上以测量其叶绿素荧光参数。

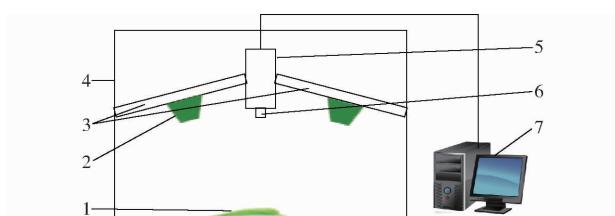


图 3 叶绿素荧光成像装置示意图

Fig. 3 Schematic of chlorophyll fluorescence imaging device

1. 辣椒样本 2. LED 光源 3. 灯架 4. 黑箱 5. 叶绿素荧光成像仪 6. 镜头 7. 数据采集计算机

### 1.3 数据预处理方法

采集过程中存在的随机噪声与一部分环境噪声会导致采集的光谱数据中存在一部分无关信息, 为提取有效信息使建模结果更准确, 需要对原始光谱数据进行预处理<sup>[12]</sup>。由于数据中头部和尾部噪声过大, 有效信息过少, 所以波长仅选用 400 ~ 1 000 nm。将辣椒叶片按不同胁迫处理方式分为重度干旱、轻度干旱、轻度水浸、重度水浸及对照组, 并按照比例

3:1 划分校正集与预测集<sup>[13]</sup>, 再分别采用有代表性的 3 种原理不同的预处理方法, 即多元散射校正 (Multiplicative scatter correction, MSC)、SG (Savitzky – Golay) 卷积平滑滤波和标准正态变量变换 (Standard normal variate transformation, SNV) 消除背景信息干扰, 增强光谱与数据之间的相关性, 在以上预处理的基础上采用全光谱分别建立径向基函数 (Radial basis function, RBF) 判别模型。

#### 1.3.1 多元散射校正

多元散射校正采用理想光谱修正光谱数据的基线平移和偏移。而实际中, 无法获取真正的理想光谱数据, 因此常常假设所有光谱数据的平均值作为“理想光谱”。该方法可以有效地消除由于散射水平不同带来的光谱差异, 从而增强光谱与数据之间的相关性。

#### 1.3.2 SG 卷积平滑滤波

SG 卷积平滑滤波是利用多项式进行数据平滑。基于最小二乘法, 能够保留分析信号中的有用信息, 消除随机噪声, 在信号图谱中最直接的结果就是将图谱的“毛刺”去掉, 整个图谱更加平滑。

#### 1.3.3 标准正态变量变换

标准正态变量变换将数据按行减去其均值, 并除以其标准差。得到的结果是, 对于每行来说所有数据都聚集在 0 附近, 方差为 1。主要用来消除固体颗粒尺寸、表面散射以及光程变化对漫反射光谱的影响。

### 1.4 特征波长提取方法

因为高光谱数据维数较大, 所以需要对预处理后的光谱数据进行降维处理。由于有监督算法的准确率高于无监督算法, 因此本文分别采用有监督算法的连续投影算法 (Successive projections algorithm, SPA) 和竞争性自适应重加权采样法 (Competitive adaptive reweighted sampling, CARS) 对水分胁迫辣椒叶片预处理后光谱数据进行特征波长提取<sup>[14]</sup>。

#### 1.4.1 连续投影法

连续投影算法是一种前向迭代搜索方法, 即从

一个波长开始,在每次迭代中加入一个新变量,直至所选变量数达到设定值  $N$ 。SPA 的目的是选择光谱信息最少冗余的波长以解决共线性问题<sup>[15-16]</sup>。在实际操作中先设定选取参数个数的最大值和最小值,然后循环迭代,计算该变量在其他未被选入变量上投影的大小,将投影向量最大的变量引入到变量组合中,建立偏最小二乘(PLS)回归模型,通过计算不同参数组合得到的均方根误差(RMSE),直至特征参数的数目达到最小 RMSE 对应的数值,循环结束。

#### 1.4.2 竞争性自适应重加权采样法

竞争性自适应重加权采样法是一种结合蒙特卡洛采样与 PLS 模型回归系数的特征变量选择方法,模仿达尔文理论中的“适者生存”原则。CARS 算法中,每次通过自适应加权采样保留 PLS 模型中回归系数绝对值权重较大的点作为新的子集,去掉权重较小的点,然后基于新的子集建立 PLS 模型。经过多次计算、选择 PLS 模型交互验证均方根误差(RMSECV)最小的子集中的波长作为特征波长<sup>[17]</sup>。

### 1.5 模型构建方法

#### 1.5.1 SVM 模型建立

支持向量机(SVM)是一种二分类模型。它的基本模型是定义在特征空间上的间隔最大的线性分类器,间隔最大使它有别于感知机;SVM 还包括核技巧,这使它成为实质上的非线性分类器。SVM 的学习策略就是间隔最大化,可形式化为一个求解凸二次规划的问题,也等价于正则化的合页损失函数的最小化问题。SVM 的学习算法就是求解凸二次规划的最优化算法<sup>[18-20]</sup>。在使用过程中,SVM 建模选择种类为二次 SVM,核函数为二次方内核,选择一对多分类方法。

#### 1.5.2 BP 神经网络

BP 神经网络模型是一种按误差逆传播算法训练的多层次前馈网络。输入信号通过中间节点作用于输出节点,经过非线性变换,产生输出信号,网络训练的每个样本包括输入量和期望输出量,网络输出值与期望输出值之间的偏差。通过调整输入节点与隐层节点的联接强度和隐层节点与输出节点之间的联接强度以及阈值,使误差沿梯度方向下降,经过反复学习训练,确定与最小误差相对应的网络参数。此时经过训练的神经网络即能对类似样本的输入信息自行处理,输出误差最小的经过非线性转换的信息<sup>[21]</sup>。

#### 1.5.3 径向基神经网络

径向基神经网络是一种 3 层神经网络,其包括输入层、隐层、输出层。从输入空间到隐层空间的变

换是非线性的,而从隐层空间到输出层空间变换是线性的。其中,隐层的作用是把向量从低维度的  $p$  映射到高维度的  $h$ ,这样低维度线性不可分的情况到高维度就可以变得线性可分。网络由输入到输出的映射是非线性的,而网络输出对可调参数而言却又是线性的<sup>[22]</sup>。由于所有的隐层神经元具有完全相同的结构,它采用局部拟合的方法去模拟非线性输入-输出的映射关系,因此 RBF 网络可以实现光谱数据的准确分类并具有一定的普遍性。

#### 1.5.4 随机森林

随机森林(Random forest, RF)是指用随机抽样的方法建立一个森林。随机指随机采样来建立模型;森林是指它包含很多独立的决策树<sup>[23-24]</sup>。该模型从原始数据中以有放回的方式随机取样得到  $n$  个训练数据集,再从每个训练数据集中随机选择  $K$  个特征( $K$  小于原始数据总共的特征),反复根据这  $K$  个特征建立  $m$  棵决策树,应用每个决策树来预测结果,并且保存所有预测的结果,最后对分类模型进行投票,计算每个预测结果的得票数,选择得票数最高的模型作为最终决策。该方法可以通过平均决策树,降低过拟合的风险。

### 1.6 模型评价

以经过不同光谱预处理以及不同特征波长提取方法提取的特征波长处的反射率为输入,以水分胁迫类别为输出,建立预测水分胁迫类别的支持向量机、BP 神经网络、径向基函数和随机森林模型,根据校正集和预测集的准确率确定最好的组合方式。准确率计算式为

$$D = \frac{S_{SD}}{X} \times 100\%$$

式中  $D$ —准确率, %

$S_{SD}$ —标准偏差

$X$ —结果平均值

## 2 结果与讨论

### 2.1 干旱和水浸胁迫对辣椒叶片叶绿素荧光参数的影响

图 4 为不同胁迫下辣椒叶片的叶绿素荧光图像,图 5 为水分胁迫分类叶绿素荧光参数  $F_v/F_m$  的箱型图。由图 4、5 可知,干旱与水浸胁迫均对辣椒的叶绿素荧光参数  $F_v/F_m$  有较大影响,随着胁迫程度的加重,  $F_v/F_m$  值也越低。在干旱胁迫下叶绿素荧光参数呈叶片中间高边缘低的分布趋势,水浸胁迫下叶绿素荧光参数呈叶片中间低边缘高的分布趋势。由文献[25-26]可知,叶绿素荧光参数  $F_v/F_m$  的值可以有效反映植物光合速率潜能。随着胁迫程

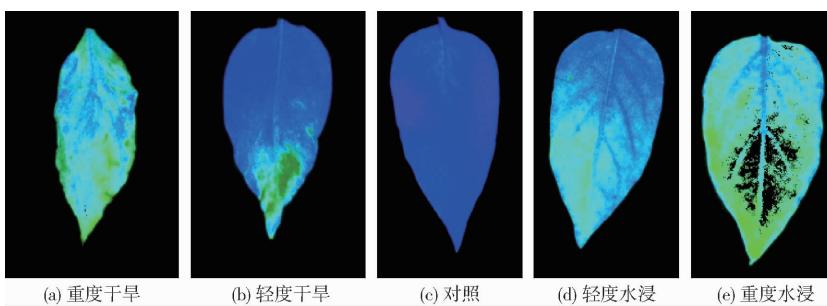
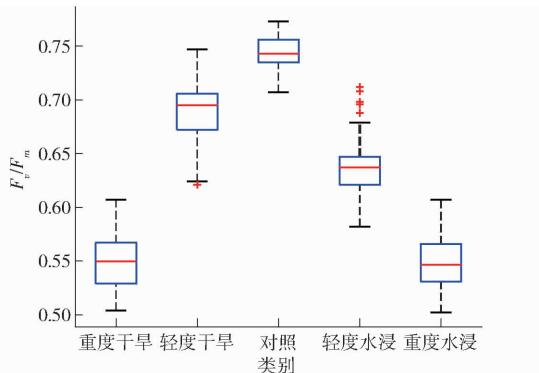


图4 不同胁迫下叶片的叶绿素荧光图像

Fig. 4 Chlorophyll fluorescence images of leaves under different stresses

图5 水分胁迫分类叶绿素荧光参数  $F_v/F_m$  的箱型图Fig. 5 Classification of water stress box diagram of chlorophyll fluorescence parameters  $F_v/F_m$ 

度加重,辣椒叶片的  $F_v/F_m$  随之降低,该结果与文献[25~26]中水分胁迫对植物生长有较大影响的结论一致。不管是干旱胁迫还是水浸胁迫,都使  $F_v/F_m$  降低,而且胁迫程度越严重,  $F_v/F_m$  降低越大。因此,仅依据  $F_v/F_m$  很难判断胁迫类别。

## 2.2 干旱和水浸胁迫对辣椒叶片高光谱的影响

图6为各胁迫下辣椒叶片在400~1 000 nm之间的平均原始反射光谱。由图6可以看出,在波长400~1 000 nm范围内,包含520~580 nm、640~690 nm和740~800 nm 3个特征峰,其中波段520~580 nm的特征峰较为明显,为叶绿素及叶黄素等吸收峰,水浸胁迫导致辣椒叶片在该波段的反射率增大,而干旱胁迫使反射率降低。波段640~690 nm为叶绿素b吸收峰,水浸胁迫导致辣椒叶片在该波

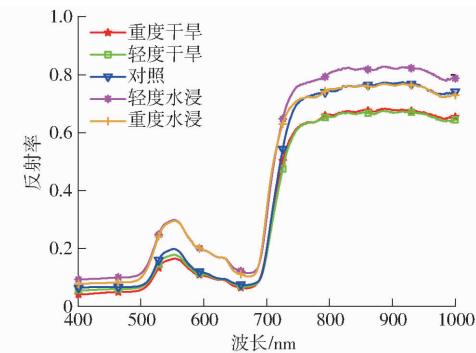


图6 各类胁迫下辣椒叶片的平均原始反射光谱

Fig. 6 Average original reflectance spectra of pepper leaves under various stresses

段的反射率降低,而干旱胁迫使反射率增大。740~800 nm为化学键中的H—O键吸收峰,与叶片中的水和醇类有关。由于水分胁迫会使叶片中叶绿素含量与叶片含水率发生变化,因此会对特征峰有一定影响,该结果符合文献[27]中的叶片成分与光谱图像之间有一定联系的结论。

## 2.3 光谱预处理算法选择

预处理结果如图7和表1所示。由图7所示,多元散射校正后各样本之间的差异降低,平滑度略有提高。SG卷积平滑滤波后光谱数据的形状、宽度不变,且光谱较为平滑。标准正态变量变换后,各样本之间的差异降低,平滑度略有提高,但数据变化较大。如表1所示,SG卷积平滑滤波后光谱数据标准偏差较大,多元散射校正处理后光谱数据标准偏差较小,且在550 nm处不同水分胁迫叶片反射率平

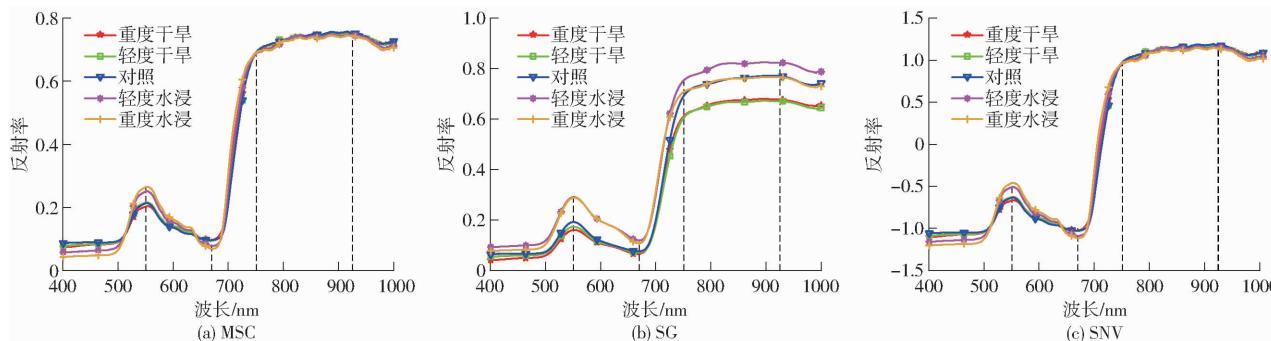


图7 3种算法预处理后不同水分胁迫的辣椒叶片反射光谱

Fig. 7 Reflectance spectra of pepper leaves under different water stresses after pretreatment with three algorithms

表 1 原始光谱与 3 种算法预处理后部分波长反射率平均值与标准差

Tab. 1 Mean and standard deviation of reflectance of partial wavelengths after original spectrum and three algorithms preprocessed

预处理方法	水分胁迫程度	波长 550 nm		波长 670 nm		波长 751 nm		波长 925 nm	
		平均值	标准偏差	平均值	标准偏差	平均值	标准偏差	平均值	标准偏差
原始数据	重度干旱	0.164 0	0.035 1	0.063 2	0.010 3	0.619 8	0.092 9	0.677 4	0.098 5
	轻度干旱	0.177 6	0.028 0	0.069 2	0.008 1	0.615 6	0.078 0	0.670 7	0.087 8
	对照	0.197 9	0.023 8	0.074 6	0.017 3	0.703 7	0.054 0	0.771 1	0.060 1
	轻度水浸	0.297 7	0.034 7	0.115 2	0.017 3	0.761 5	0.084 2	0.825 0	0.095 1
	重度水浸	0.294 5	0.040 2	0.103 0	0.016 3	0.712 9	0.071 7	0.765 7	0.080 5
MSC	重度干旱	0.202 7	0.010 6	0.096 9	0.005 5	0.687 0	0.008 6	0.748 7	0.008 8
	轻度干旱	0.215 3	0.022 4	0.094 0	0.011 0	0.690 8	0.007 2	0.750 6	0.004 7
	对照	0.212 9	0.009 8	0.096 2	0.005 0	0.691 0	0.003 6	0.754 6	0.003 8
	轻度水浸	0.250 6	0.011 6	0.078 0	0.006 5	0.687 3	0.006 9	0.746 5	0.004 4
	重度水浸	0.264 4	0.017 9	0.068 6	0.009 9	0.689 3	0.005 1	0.742 6	0.004 9
SG	重度干旱	0.160 1	0.034 1	0.066 3	0.011 0	0.611 7	0.093 2	0.676 7	0.098 2
	轻度干旱	0.173 1	0.027 5	0.071 7	0.008 3	0.605 5	0.075 5	0.670 6	0.089 4
	对照	0.191 8	0.023 3	0.076 5	0.017 2	0.693 0	0.053 2	0.770 0	0.060 0
	轻度水浸	0.290 8	0.034 1	0.119 3	0.017 5	0.753 3	0.084 0	0.823 7	0.095 0
	重度水浸	0.288 0	0.039 4	0.108 5	0.017 3	0.707 6	0.071 8	0.765 2	0.080 8
SNV	重度干旱	0.669 2	0.035 1	1.024 1	0.019 1	0.955 2	0.028 8	1.161 9	0.029 2
	轻度干旱	0.626 5	0.074 4	1.033 2	0.038 1	0.967 3	0.024 0	1.167 7	0.015 7
	对照	0.634 8	0.032 6	1.026 2	0.017 3	0.968 1	0.012 0	1.181 3	0.012 6
	轻度水浸	0.508 7	0.039 3	1.087 6	0.021 2	0.956 1	0.023 2	1.154 9	0.015 0
	重度水浸	0.461 2	0.061 2	1.116 0	0.029 4	0.960 3	0.018 1	1.138 7	0.019 1

均值均有较大区别。

表 2 为采用不同预处理后的全光谱建立的 RBF 判别模型对 5 种不同水分胁迫程度辣椒叶片的识别结果。其中,所有预处理方法所对应的训练集准确率均为 100%。基于 MSC 处理后的测试集准确率为 90.00%,基于 SG 卷积平滑处理后的测试集准确率为 96.00%,基于 SNV 处理后的测试集准确率为 88.00%。由于实验仪器存在一定的信号波动,因此所测得光谱数据含有大量随机噪声,SG 预处理利用多项式进行数据平滑。基于最小二乘法能够保留分析信号中的有用信息,消除随机噪声,有效提高模型准确度,为此,将 SG 预处理作为光谱预处理方法。

表 2 3 种算法预处理后 RBF 模型训练集与测试集准确率

Tab. 2 Accuracy of RBF model training set and test set after pre-processing of three algorithms %

预处理方法	训练集准确率	测试集准确率
MSC	100	90
SG	100	96
SNV	100	88

## 2.4 特征波长提取结果

对 SG 预处理后的光谱采用 SPA 进行特征波长筛选时,设置选择参数最大值和最小值分别为 150 和 1,最终筛选出 33 个特征波长,其均方根误差为

0.318 7,占全光谱波段的 7.3%。其中波长 640~680 nm 范围的特征波长有 4 个,波长 901~950 nm 范围的特征波长有 5 个,波长 951~1 000 nm 范围的特征波长有 6 个。SPA 算法提取的特征波长如图 8 所示。

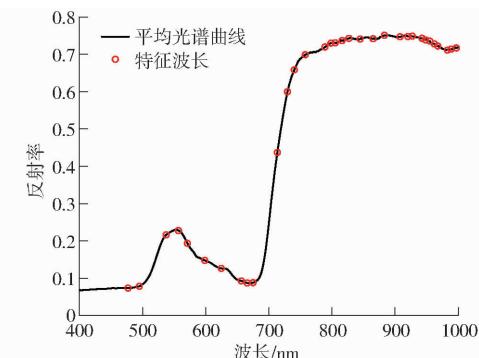


图 8 SPA 算法提取的特征波长

Fig. 8 Feature wavelength extracted by SPA algorithm

对 SG 预处理后的光谱采用 CARS 算法进行特征波长筛选,最终筛选出 53 个特征波长,其交互验证均方根误差(RMSECV)为 0.451 7,占全光谱波段的 11.7%。其中波长 510~560 nm 范围的特征波长有 6 个,波长 640~660 nm 范围的特征波长有 8 个,波长 970~1 000 nm 范围的特征波长有 12 个。CARS 算法提取的特征波长如图 9 所示。

根据上文分析可知,波长 520~560 nm 属于可

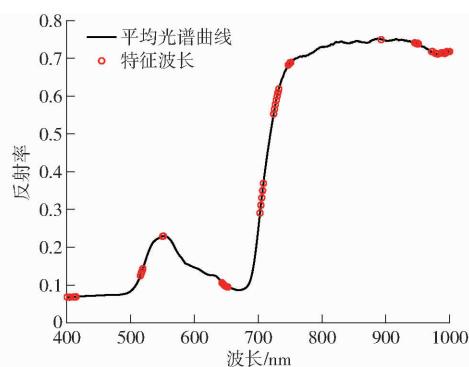


图 9 CARS 算法提取的特征波长

Fig.9 Characteristic wavelength extracted by CARS algorithm

见光范围,其中植物叶绿素、叶黄素及类胡萝卜素等对其影响较大,波长 850~900 nm 主要对应的是  $\text{C}\equiv\text{H}$  基团,波长 901~950 nm 主要对应的是  $\text{C}=\text{H}$  和  $\text{C}-\text{H}$  基团,波长 951~1 000 nm 主要对应的是  $\text{H}_2\text{O}$  分子。因此由本实验结果可知,辣椒在水分胁迫时叶片中叶绿素含量、部分有机物含量和叶片含水率均会发生显著变化。该结果符合文献[28~31]中干旱与水浸胁迫均会使植物叶片中叶绿素含量与叶片含水率降低的结论。

## 2.5 水分胁迫判别模型性能对比

表 3 为基于从 SG 预处理光谱中提取的特征波长所建的不同模型对辣椒不同胁迫程度的判别结果。

表 3 基于不同特征波长提取方法从 SG 预处理光谱中提取的特征波长数及不同建模对辣椒叶片胁迫程度的识别结果

Tab. 3 Number of characteristic wavelengths extracted from SG preprocessing spectra and recognition results of stress degree of pepper leaves by different obtained modeling methods

建模方法	特征波长提取方法	提取的特征波长数	训练集准确率/%	测试集准确率/%
SVM	SPA	33	55.61	54.00
	CARS	53	58.05	50.00
BP	SPA	33	95.12	88.00
	CARS	53	93.17	90.00
RBF	SPA	33	99.02	94.00
	CARS	53	100	90.00
RF	SPA	33	100	72.00
	CARS	53	100	74.00

当模型为 SVM 时,基于 SPA 提取的特征波长所建模型(SPA-SVM)的预测准确率(54.00%)高于基于 CARS 提取的特征波长所建模型(50.00%),但总体预测准确率低。

当模型为 BP 时,基于 CARS 提取的特征波长所建模型(CARS-BP)的预测准确率(90.00%)高于基于 SPA 提取的特征波长所建模型(88.00%)。

当模型为 RBF 时,基于 SPA 提取的特征波长所建模型(SPA-RBF)的预测准确率(94.00%)高于基于 CARS 提取的特征波长所建模型(90.00%),整体预测准确率较高。

当模型为 RF 时,基于 CARS 提取的特征波长所建模型(CARS-RF)的预测准确率(74.00%)高于基于 SPA 提取的特征波长所建模型(72.00%),总体预测准确率偏低。

4 种模型相比,由于 RBF 模型是一种 3 层神经网络,其包括输入层、隐层、输出层,且所有的隐层神经元具有完全相同结构,它采用局部拟合的方法去模拟非线性输入-输出的映射关系,因此 RBF 模型可以实现光谱数据的准确分类。基于 SPA 提取的特征波长所建的 RFB 模型(SPA-RBF)准确率最高且特征波长数较少,认为 SG-SPA-RBF 组合为最优组合。此模型可靠性高,响应时间较短,有较强应用价值。

## 3 结论

(1) 干旱胁迫导致可见光波段(波长 400~700 nm)内辣椒叶片反射率增大,而水浸胁迫降低了反射率。

(2) 对辣椒叶片原始光谱采用 3 种方法进行预处理,通过 RBF 模型对 3 种预处理后的全光谱进行建模,得到 SG 预处理效果最好,其预测准确率最高,其中训练集准确率为 100%,测试集准确率为 96.00%,后续处理基于这种预处理方法进行。

(2) 基于 SPA 和 CARS 算法分别从 SG 预处理后的光谱中提取 33 和 53 个特征波长,占全光谱的 7.3% 和 11.7%。基于前者所建的 RBF 模型识别辣椒水分胁迫种类与程度的训练集准确率为 99.02%,测试集准确率为 94.00%。

## 参 考 文 献

- [1] CHEN Sizhou, SHEN Jiazhi, FAN Kai, et al. Hyperspectral machine-learning model for screening tea germplasm resources with drought tolerance[J]. Frontiers in Plant Science, 2022, 13:1048442.
- [2] ZHANG Gen, HUANG Jianping, MA Yongjun, et al. Hyperspectral imaging with a band matrix reduction method to detect early drought stress in tomato[J]. Ciéncia e Tecnologia de Alimentos, 2023, 43:123322.
- [3] CHEN S, GAO Y, FAN K, et al. Prediction of drought-induced components and evaluation of drought damage of tea plants

- based on hyperspectral imaging[J]. *Front Plant Science*, 2021, 12:695102.
- [4] GUO Congcong, LIU Liantao, SUN Hongchun, et al. Predicting  $F_v/F_m$  and evaluating cotton drought tolerance using hyperspectral and 1D-CNN[J]. *Frontiers in Plant Science*, 2022, 13:1007150.
- [5] CHEN Siluo, TUSSCHER K, SASIDHARAN R, et al. Parallels between drought and flooding: an integrated framework for plant eco-physiological responses to water stress[J]. *Plant-environment Interactions*, 2023, 4(4):175–187.
- [6] LIN H H, LIN K H, HUANG M Y, et al. Use of non-destructive measurements to identify cucurbit species (*Cucurbita maxima* and *Cucurbita moschata*) tolerant to waterlogged conditions[J]. *Plants*, 2020, 18(9):1226–1240.
- [7] 徐鹏, 顾晓鹤, 孟鲁闽, 等. 洪涝胁迫的水稻叶面积指数变化及其光谱响应研究[J]. 光谱学与光谱分析, 2013, 33(12):3298–3302.
- XU Peng, GU Xiaohe, MENG Lumin, et al. Change of LAI and spectral response for rice under flood and waterlogging stress [J]. *Spectroscopy and Spectral Analysis*, 2013, 33(12):3298–3302. (in Chinese)
- [8] 邹学校, 马艳青, 戴雄泽, 等. 辣椒在中国的传播与产业发展[J]. 园艺学报, 2020, 47(9):1715–1726.
- ZOU Xuexiao, MA Yanqing, DAI Xiongze, et al. The spread and industrial development of chili in China [J]. *Acta Horticulture Sinica*, 2020, 47(9):1715–1726. (in Chinese)
- [9] 乔立娟, 赵帮宏, 宗义湘, 等. 我国辣椒产业发展现状、趋势及对策[J]. 中国蔬菜, 2023(11):9–15.
- QIAO Lijuan, ZHAO Banghong, ZONG Yixiang, et al. Development status, trend and countermeasures of chili industry in China [J]. *China Vegetables*, 2023(11):9–15. (in Chinese)
- [10] 郭文川, 董金磊. 高光谱成像结合人工神经网络无损检测桃的硬度[J]. 光学精密工程, 2015, 23(6):1530–1537.
- GUO Wenchuan, DONG Jinlei. Nondestructive detection on firmness of peaches based on hyperspectral imaging and artificial neural networks[J]. *Optics and Precision Engineering*, 2015, 23(6):1530–1537. (in Chinese)
- [11] 卢苗, 完香蓓, 袁凯凯, 等. 冷害对黄瓜光系统Ⅱ潜在活性的影响[J]. 西北农林科技大学学报(自然科学版), 2022, 50(10):116–124, 134.
- LU Miao, WAN Xiangbei, YUAN Kaikai, et al. Influence of chilling injury on potential activity of cucumber photosystem II [J]. *Journal of Northwest A&F University(Natural Science Edition)*, 2022, 50(10):116–124, 134. (in Chinese)
- [12] 高升, 王巧华, 施行, 等. 便携式红提葡萄多品质可见/近红外检测仪设计与试验[J]. 农业机械学报, 2021, 52(2):308–319.
- GAO Sheng, WANG Qiaohua, SHI Hang, et al. Design and test of portable red globe grape extraction multi-quality visible nearinfrared detector[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(2):308–319. (in Chinese)
- [13] 赵娟, 沈懋生, 浦育歌, 等. 基于近红外光谱与多品质指标的苹果出库评价模型研究[J]. 农业机械学报, 2023, 54(2):386–395.
- ZHAO Juan, SHEN Maosheng, PU Yuge, et al. Out-of-warehouse evaluation and prediction model of apple based on nearinfrared spectroscopy combined with multiple quality indexes[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(2):386–395. (in Chinese)
- [14] 李斌, 高攀, 冯盼, 等. 基于可见-近红外光谱的茄子叶绿素荧光参数  $F_v/F_m$  预测方法[J]. 光谱学与光谱分析, 2020, 40(9):2834–2839.
- LI Bin, GAO Pan, FENG Pan, et al. Prediction of eggplant leaf  $F_v/F_m$  based on vis-NIR spectroscopy[J]. *Spectroscopy and Spectral Analysis*, 2020, 40(9):2834–2839. (in Chinese)
- [15] YUAN Ruirui, LIU Guishan, HE Jianguo, et al. Classification of Lingwu long jujube internal bruise over time based on visible near-infrared hyperspectral imaging combined with partial least squares-discriminant analysis[J]. *Computers and Electronics in Agriculture*, 2021, 182:106043.
- [16] ZHU Guozhen, TIAN Chunna. Determining sugar content and firmness of ‘Fuji’ apples by using portable near-infrared spectrometer and diffuse transmittance spectroscopy[J]. *Journal of Food Process Engineering*, 2018, 41:12810.
- [17] 李庆旭, 王巧华, 马美湖, 等. 基于可见/近红外光谱和深度学习的早期鸭胚雌雄信息无损检测[J]. 光谱学与光谱分析, 2021, 41(6):1800–1805.
- LI Qingxu, WANG Qiaohua, MA Meihu, et al. Non-destructive detection of male and female information in early duck embryo based on visible/near infrared spectroscopy and deep learning[J]. *Spectroscopy and Spectral Analysis*, 2021, 41(6):1800–1805. (in Chinese)
- [18] MOHAMMADI P, ASEFOUR V K. Machine learning provides specific detection of salt and drought stresses in cucumber based on miRNA characteristics[J]. *Plant Methods*, 2023, 19(1):123.
- [19] FLYNN K C, BAATH G, LEE T O, et al. Hyperspectral reflectance and machine learning to monitor legume biomass and nitrogen accumulation[J]. *Computers and Electronics in Agriculture*, 2023, 211:107991.
- [20] PHILLIPS T, ABDULLA W. A new honey adulteration detection approach using hyperspectral imaging and machine learning [J]. *European Food Research & Technology*, 2023, 249(2):259–272.
- [21] 朱燕萍, 崔传金, 程朋飞, 等. 三维荧光光谱结合BP神经网络和SWATLD测量油类污染物[J]. 光谱学与光谱分析, 2023, 43(8):2467–2475.
- ZHU Yanping, CUI Chuanjin, CHENG Pengfei, et al. 3D fluorescence spectrum combined with BP neural network and swatld to measure oil pollutants[J]. *Spectroscopy and Spectral Analysis*, 2023, 43(8):2467–2475. (in Chinese)
- [22] TAVAEN S, KAENNAKHAM S. Numerical comparison of shapeless radial basis function networks in attern recognition[J].

- Computers, Materials & Continua, 2023, 74(2):4081 – 4098.
- [23] GUPTA A, KAUR L, KAUR G. Drought stress detection technique for wheat crop using machine learning[J]. Computer Science, 2023, 9:e1268.
- [24] SUN Jie, HU Yan, ZOU Yulin, et al. Identification of pesticide residues on black tea by fluorescence hyperspectral technology combined with machine learning[J]. Food Science and Technology, 2022, 42:55822.
- [25] ZHANG Huihui, XU Nan, TENG Zhiyuan, et al. 2-Cys Prx plays a critical role in scavenging H<sub>2</sub>O<sub>2</sub> and protecting photosynthetic function in leaves of tobacco seedlings under drought stress[J]. Journal of Plant Interactions, 2019, 14(1): 119 – 128.
- [26] QI Miao, LIU Xiaodi, LI Yibo, et al. Photosynthetic resistance and resilience under drought, flooding and rewetting in maize plants[J]. Photosynthesis Research, 2021, 148(1–2):1 – 15.
- [27] PAN Weidong, CHENG Xiaodong, DU Rongyu, et al. Detection of chlorophyll content based on optical properties of maize leaves[J]. Molecular and Biomolecular Spectroscopy, 2024, 309:123843.
- [28] RIDWAN, HAMIM, SUHARSONO, et al. Drought stress induced the flavonoid content in moringa (*Moringa oleifera* Lam.) leaves[J]. Sains Malaysiana, 2023, 52(1):57 – 69.
- [29] ORSÁK M, KOTÍKOVÁ Z, HNILIČKA F, et al. Effect of long-term drought and waterlogging stress on photosynthetic pigments in potato[J]. Plant, Soil and Environment, 2023, 69(4):152 – 160.
- [30] REZWAN M MOTIAR R, ROBYUL I, et al. Screening and evaluation of chilli (*Capsicum annuum* L.) genotypes for waterlogging tolerance at seedling stage[J]. Biocell, 2022, 46(7):1613 – 1627.
- [31] KOH S S, DEV K, TAN J J, et al. Classification of plant endogenous states using machine learning-derived agricultural indices[J]. Plant Phenomics, 2023, 5:60.

(上接第335页)

- [22] 杨断利, 王永胜, 陈辉, 等. 基于改进 YOLO v6 – tiny 的蛋鸡啄羽行为识别与个体分类[J]. 农业机械学报, 2023, 54(5): 268 – 277.  
YANG Duanli, WANG Yongsheng, CHEN Hui, et al. Feather pecking abnormal behavior identification and individual classification method of laying hens based on improved YOLO v6 – tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 268 – 277. (in Chinese)
- [23] JIN Z, GUO L, SHU H, et al. Behavior classification and analysis of grazing sheep on pasture with different sward surface heights using machine learning[J]. Animals, 2022, 12(14): 1744.
- [24] GIOVANETTI V, DECANDIA M, MOLLE G, et al. Automatic classification system for grazing, ruminating and resting behaviour of dairy sheep using a tri-axial accelerometer[J]. Livestock Science, 2017, 196: 42 – 48.
- [25] SHEND H, ZHANG S, ZUO L, et al. Construction of sheep forage intake estimation models based on sound analysis[J]. Biosystems Engineering, 2020, 192: 144 – 158.
- [26] DUAN G H, ZHANG S F, LU M Z, et al. Short-term feeding behaviour sound classification method for sheep using LSTM networks[J]. International Journal of Agricultural and Biological Engineering, 2021, 14(2): 43 – 45.
- [27] WANG K, WU P, CUI H, et al. Identification and classification for sheep foraging behavior based on acoustic signal and deep learning[J]. Computers and Electronics in Agriculture, 2021, 187: 106275.
- [28] 张春慧, 宣传忠, 于文波, 等. 基于三轴加速度传感器的放牧羊只牧食行为研究[J]. 农业机械学报, 2021, 52(10): 307 – 313.  
ZHANG Chunhui, XUAN Chuanzhong, YU Wenbo, et al. Grazing behavior of herding sheep based on three-axis acceleration sensor[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 307 – 313. (in Chinese)
- [29] KLEANTHOUS N, HUSSAIN A, KHAN W, et al. Deep transfer learning in sheep activity recognition using accelerometer data[J]. Expert Systems with Applications, 2022, 207: 117925.
- [30] 刘艳秋, 宣传忠, 武佩, 等. 基于 K-means – BP 神经网络的舍饲环境母羊产前运动行为分类识别[J]. 中国农业大学学报, 2021, 26(3): 86 – 95.  
LIU Yanqiu, XUAN Chuanzhong, WU Pei, et al. Classification and recognition on movement behaviors of ewes in house feeding environment based on K-means and BP neural network[J]. Journal of China Agricultural University, 2021, 26(3): 86 – 95. (in Chinese)
- [31] 陆明洲, 梁钊董, NORTON T, 等. 基于 EfficientDet 网络的湖羊短时咀嚼行为识别方法[J]. 农业机械学报, 2021, 52(8): 248 – 254, 426.  
LU Mingzhou, LIANG Zhaodong, NORTON T, et al. Automatic identification method of short-term chewing behaviour for sheep based on EfficientDet network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(8): 248 – 254, 426. (in Chinese)
- [32] WANG C Y, BOCHKOVSKIY A, LIAO MARK H Y. YOLO v7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[J]. arXiv preprint arXiv: 2207. 02696, 2022.