谢东,何敬,何嘉晨,等.基于无人机高光谱影像的水稻叶片SPAD值反演方法研究[J].山西农业大学学报(自然科学版),2024,44(1):120-129.
Xie D, He J, He J C, et al. Inversion method of rice leaf SPAD values based on UAV hyperspectral imagery[J]. Journal of Shanxi Agricultural University(Natural Science Edition), 2024,44(1):120-129.
doi: 10.13842/j.cnki.issn1671-8151.202308034

基于无人机高光谱影像的水稻叶片SPAD值反演方法研究

谢东[1],何敬[1*],何嘉晨[1],王彬[1],林远杨[1],刘刚[1,2]

(1.成都理工大学 地球科学学院,四川 成都 610059;
2.成都理工大学 地质灾害防治与地质环境保护国家重点实验室,四川 成都 610059)

摘　要:[目的]通过无人机高光谱影像实现对水稻叶绿素含量高效、无损监测是现代化精准农业发展的重要手段。研究水稻叶片原始光谱的不同预处理方法及其组合,构建不同光谱参数进行模型反演,得到研究区水稻叶片SPAD值的最佳反演模型,可为高效无损监测水稻叶绿素含量提供参考。[方法]以四川省成都市青白江区姚渡镇水稻种植区的水稻为研究对象,分别测定其叶片SPAD值和500~900 nm范围内的高光谱反射率,对原始反射率进行一阶微分(D1)、Savitzky-Golay卷积平滑(SG平滑)、标准正态变换(SNV)和多元散射校正(MSC)及其组合的预处理方式,通过相关系数筛选出$p<0.1$的特征波段作为第1种光谱参数,在特征波段的基础上进行主成分分析(PCA)降维,将得到的主成分作为第2种光谱参数。将2种参数分别作为Extra Trees模型的输入变量,建立研究区水稻SPAD值的反演模型。[结果]相比于利用相关系数筛选的特征波段所建的模型,通过PCA对特征波段进行降维,得到的光谱参数建模精度更高,其中,ET_D1和ET_SG_MSC的R^2分别由0.769和0.782增加到0.793和0.825,提升幅度为3%和5.5%;ET_SG_SNV的R^2由0.754增加到0.796,提升幅度为5.6%;模型ET_PCA_特征_SG_MSC精度最高,R^2和RMSE分别为0.825和0.984,是研究区水稻SPAD值的最佳反演模型。[结论]研究结果可为实现高效、精准的水稻叶片叶绿素含量监测提供参考及依据。

关键词:水稻;叶绿素;高光谱;相关系数;主成分分析;Extra　Tress
中图分类号:S511　　**文献标识码**:A　　**文章编号**:1671-8151(2024)01-0120-10

水稻作为我国主要粮食作物,占全国粮食播种面积的27%,在我国粮食生产中占有重要地位[1]。水稻进行光合作用和物质积累的主要场所是叶片,水稻叶片的叶绿素含量表征了水稻的营养和生长状况,是植物营养胁迫、光合作用、叶片氮素含量以及各阶段生长发育状况的重要指示剂[2-5]。传统的叶片叶绿素检测方法中最常见的是分光光度法[5-6],不仅会造成叶片结构的损害,并且十分费时费力。此外,叶绿素具有结构不稳定、见光易分解的特点,这会导致测量值和实际含量之间存在一定误差[7]。研究表明便携式叶绿素仪测定的叶片叶绿素相对含量(SPAD值)与叶绿素含量呈正相关[8],因此SPAD值能够代替通过化学分析方法检测出的叶绿素含量,实现叶片叶绿素的高效、无损检测。

借助于高光谱遥感技术对植物特别是农作物进行SPAD值的快速、准确、无损的获取与监测等方面研究已经取得了突出的进展[9-10]。与多光谱遥感相比,高光谱遥感对植物生理生化参数的变化感知更加敏感,反映的特征更加精细,这为准确估算植被生理生化参数提供了良好的基础[11-13]。

无人机作为低空遥感的一种方式,操作简单,起飞条件宽松,机动性、灵活性高,可以获取高空间、高光谱分辨率的遥感影像[14]。因此,近年来利

收稿日期:2023-08-22　　**修回日期**:2023-11-18
基金项目:自然资源部成都平原国土生态与土地利用野外科学观测研究站开放基金(CDORS-2023-04);成都市技术创新研发项目(2022-YF05-01090-SN);成都理工大学研究生质量工程项目(2022YJG022)
作者简介:谢东(ORCID:0009-0006-1872-4324),硕士研究生,研究方向:高光谱微量元素反演,Email:xie218dong@163.com
*通信作者:何敬(ORCID:0000-0002-2224-9304),博士,副教授,硕士生导师,Email:xiao00yao@163.com

用无人机高光谱遥感数据监测作物SPAD值的方法已被广泛应用。常潇月等[15]利用无人机平台搭载高光谱相机获得玉米农田高光谱影像,从中提取了光谱参数进行玉米叶片叶绿素含量估测,结果显示以红边一阶微分最大值为自变量构建的回归模型建模精度最高。尹航等[16]利用无人机为平台搭载S185光谱仪获取马铃薯试验区高光谱影像,通过波段优化算法建立优化光谱指数和马铃薯叶绿素含量估测模型,发现通过优化波段建立的光谱指数能够明显提高模型准确性。袁炜楠等[17]针对无人机高光谱遥感数据的高维特性,提出一种基于主基底分析的降维方法,并建立最小二乘回归模型对水稻冠层叶片叶绿素含量进行估算,结果表明与3种植被指数降维后建立的模型相比,该方法的建模精度有了很大提升。

在对高光谱数据的前期处理方面,已有学者分别采用标准正态变换、多元散射校正、基线校正、卷积平滑滤波和一阶导数等预处理方法,分析比较了线性回归、偏最小二乘、支持向量机、BP神经网络和随机森林等模型预测作物叶片营养元素的效果[18-22]。还有学者采用7种光谱预处理方法及其组合,结合偏最小二乘、支持向量回归和随机森林3种模型,建立了光谱反射率与水稻叶片SPAD值的映射关系,比较了不同组合的预测精度[23]。陈志超等[24]通过5种方法对提取的春玉米冠层高光谱信息进行预处理,并分别采用偏最小二乘回归、BP神经网络回归和随机森林回归3种算法构建春玉米氮营养指数反演模型,结果表明随机森林算法结合MSC预处理反演效果最好。

在波段降维方面,姚付启等[25]采用主成分分析对原始光谱进行降维,将得到的主成分作为BP人工神经网络模型的输入变量,实现了对法国梧桐叶绿素含量的估算。孙小香等[26]利用主成分分析对原始光谱数据进行降维,结合逐步多元线性回归和支持向量回归构建了叶片SPAD值的高光谱估算模型。刘文雅等[27]将对马尾松冠层原始光谱进行主成分分析降维后的前4个主成分以及筛选出的植被指数和红边参数作为BP神经网络的输入变量构建叶绿素含量的高光谱估算模型,发现基于主成分分析的特征参数预测效果最好。

现有研究在对原始光谱进行多种预处理后直接将全波段光谱作为自变量代入模型中进行作物参量的预测,仅考虑不同预处理方式对建模精度的影响,忽略了波段信息冗余和无关信息干扰等问题;此外前人在使用主成分分析时大多选择对原始光谱进行降维,基于特征波段进行PCA降维的建模效果需要进一步研究。本文将几种预处理方法进行组合,在其基础上基于相关系数提取特征波段作为第1种光谱参数,在第1种光谱参数的基础上,进行主成分分析,将提取到的主成分作为第2种特征参数。最后将2种光谱参数代入Extra Trees模型中进行训练和预测,对比分析两种光谱参数结合模型的预测效果,并优选出研究区最佳水稻SPAD值反演模型。

1　研究区与研究方法

1.1　研究区概况

研究区(图1)位于我国四川省成都市青白江区姚渡镇(104°19′E,30°42′N)水稻产区,总面积71.72 km^2。研究区属于亚热带温和湿润气候,年平均气温16.5 ℃,年平均降水量900 mm,无霜期平均300 d,年平均日照时数1 298.2 h,光照条件适合水稻等粮食作物的生长。

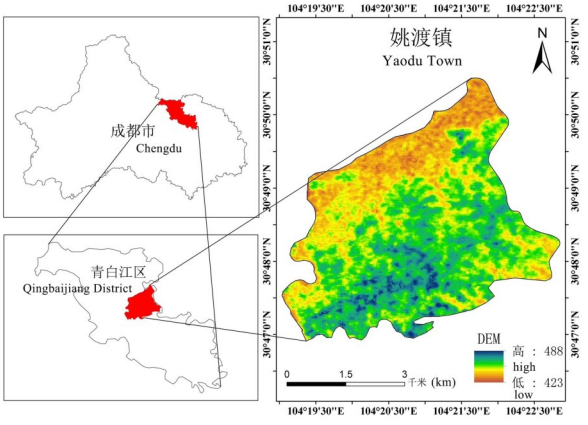

图1　研究区位置

Fig.1　The location of the research area

1.2　水稻叶片SPAD值及光谱测定

1.2.1　试验方案

在试验田中布置了2个试验小区,每个小区面积为7.8 m×7.8 m。试验在试验田布置小区内进行,共准备10个40 cm×40 cm的白色样方,在样方的4个角分别用红、黄、蓝和黑色胶带固定住。在距离试验小区边界1 m的位置,根据五点采样法在小区内进行样方摆放,4边样方的间距为5 m,在

试验小区正中央放置1个样方,白板放置在距离2个小区位置相同处。

1.2.2 SPAD值测定

采用手持式叶绿素仪(SPAD 502 Plus, KONICA MINOLTA, Japan)测定水稻叶片SPAD值:对每个样本点的水稻顶端完全展开的3片健康且形状大小均匀的叶片,分别测量距离叶端1/3和2/3处2个部位的SPAD值,每个部位测量3个点,测量时注意避开叶脉部分,取6个数值的平均值作为该叶片的SPAD值,最后取3片叶片的SPAD平均值作为该样本点叶片的最终SPAD值。数据采集时沿着每个样方4个角的不同颜色按照固定顺序进行采集,每个样方共采集6个水稻样本点,2个试验田小区共采集60个样本点。

1.2.3 光谱测定

使用大疆M600Pro搭载SENOP RIKOLA高光谱仪作为本次试验的遥感平台,高光谱仪参数如表1所示。无人机高光谱数据采集和地面SPAD值采样同时进行,每次数据采集之前均进行白板校正,以保证采集的数据质量。采集时间为11:00-14:00[28],天气晴朗,无风干扰。无人机拍摄高度为30 m[29],曝光时间为0.5 s。

表1 SENOP RIKOLA参数

Table 1 The parameters of SENOP RIKOLA

产地 Origin	成像方式 Imaging method	光谱范围/nm Spectral range	视场角/° Field of view	空间分辨率 Spatial resolution	光谱分辨率/nm Spectral resolution
芬兰	框幅	500~900	36.5	1010*1010 pixels	>10

1.3 数据处理

利用SENOP RIKOLA自带软件对采集的高光谱数据进行暗电流校正、波段配准以及辐射定标,从而得到原始数据,再从中挑选出效果好的影像作为进一步研究的实验数据。将选择的影像导入ENVI 5.3,在影像范围内均匀地选取60个叶片进行打点,所选取叶片的形态、长势要能代表整个研究区。最后将选取的60个叶片点的光谱反射率导出到Excel 2016中进行整理,得到本实验所研究的60个水稻叶片的原始光谱反射率数据,每个样本含有48个波段。

本文参考传统光谱预处理方法,选用了Savitzky-Golay平滑(SG)、一阶微分变换(DI)、SG平滑与标准正态变换(SG_SNV)、SG平滑与多元散射校正(SG_MSC)对原始光谱进行处理。其中,SG平滑能在一定程度上提高图谱信噪比,降低随机噪音对光谱的影响;D1可以消除背景土壤对水稻叶片反射率观测的影响;MSC和SNV主要用来消除由于颗粒分布不均匀或颗粒大小不同而出现的散射对原始光谱造成的影响[30]。

1.4 光谱参数筛选

高光谱影像波段数量多,含有丰富的光谱信息,可以为不同地物的研究提供良好的基础。但是,复杂的波段也会伴随着数据冗余、含有大量与研究无关信息等问题,通常采取光谱参数筛选的方法来选取与试验相关的波段进行进一步的研究。此外,对于本文的研究对象,水稻冠层的波段反射率容易被土壤背景、大气状况以及作物自身的饱和状态所影响,因此需要通过光谱参数筛选来减少这一系列的影响。

1.4.1 基于相关性分析的光谱参数筛选

相关性分析是一种评价2个或多个存在一定联系的指标之间相关程度的方法,用来衡量这些变量之间相关程度的指标是Pearson系数(r)和显著性值(p)。其中r的取值范围在-1和1之间,其值越接近-1或1,表示2个变量间相关程度越高,反之则相关性程度越低;对p而言,$p<0.1$、$p<0.5$和$p<0.01$分别对应着10%显著相关、5%显著相关和1%显著相关,若p值在0.05和0.1之间,说明2变量间存在一定的线性关联;若p值在0.01和0.05之间,说明2变量之间存在显著的线性关联;若p值小于0.01,则说明2变量之间存在极显著的线性关联。

1.4.2 基于PCA降维的光谱参数筛选

主成分分析(PCA)是由Pearson于1901年提出的一种分析、简化数据集的方法。PCA通过对数据进行线性变换和压缩的方式实现了以较少的主成分保留原数据中绝大部分信息的目的,不仅可以有效降低数据集的维度,剔除不必要的信息,还能有效消除变量间的共线性问题。

1.5 模型构建

Extra Trees(ET)是由Pierre Geurts等人于2006年提出的一种集成学习方法,通过一些去相关化的决策树来进行分类,其算法与随机森林十

分相似,都是由许多决策树构成。两者的主要区别有2点,其一在于随机森林应用的是Bagging模型,而ET使用的是所有的训练样本来得到每棵决策树,也就是每棵决策树应用的是相同的全部训练样本,因为分裂是随机的,所以在某种程度上比随机树得到的结果更好[31];其二在于随机森林是在一个随机子集内得到最佳分叉属性,而ET是完全随机地得到分叉值,从而实现对决策树的分叉。对于某一棵决策树来说,由于它的最佳分叉属性是随机选择的,因此单一决策树的预测结果往往是不准确的,但是很多棵决策树组合在一起,就可以达到很好地预测效果。

本试验所应用的ET模型于Python 3环境进行编译,训练集和验证集的划分通过train_test_splitt()函数实现,验证集比例设置为30%,模型的误差估算采用10折交叉验证(10-flod Cross Validation),使用Grid-SearchCV()函数通过遍历参数组合选择最优超参数进而提高模型的预测精度和鲁棒性。

1.6　精度评估

建模精度由训练集决定系数R_c^2、验证集决定系数R_p^2、均方根误差(RMSE)和相对分析误差(RPD)共同决定[32],本文选用R^2和RMSE作为评价指标对Extra Trees的估算精度进行评估。其中R^2越大,RMSE越小,意味着模型的综合能力越好。其中,R^2主要体现模型的拟合效果,RMSE则反映了模型的稳定性。

2　结果与分析

2.1　水稻叶片SPAD值与光谱分析

实验测得的60个水稻叶片的SPAD值统计见表2,概率密度函数如图2。研究区水稻叶片SPAD值范围为34.98~49.30,其中均值为44.69,标准差为2.61,变异系数为5.8%,SPAD值样本可满足反演的范围要求[33]。

表2　水稻叶片SPAD含量统计

Table 2　Statistic analysis of SPAD content in rice leaves

样本数量 Number	最大值 Max	最小值 Min	平均值 Mean	标准差 SD	变异系数/% Coefficient
60	49.30	34.98	44.69	2.61	5.8

对采集到的60个样本点的水稻叶片原始光谱反射率进行SG平滑处理,处理后的光谱曲线如图3所示。可见,水稻叶片光谱反射率变化基本呈现相同的趋势。宏观上看,反射率在可见光波段(500~780 nm)较低,在近红外波段(780~900 nm)较高。其中,反射率在绿光波段(550 nm)附近出现1个明显的反射峰值,在蓝光波段(680 nm)附近出现1个吸收谷值,在680~750 nm波段内,反射率急剧攀升,从而在近红外波段(780~900 nm)内形成了植物光谱所特有的高反射率区间。总的来说,在可见光波段,水稻叶片色素对于绿光进行了反射,对蓝光和红光则吸收强烈。

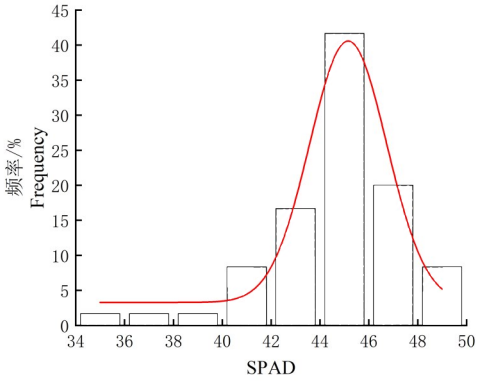

图2　总体样本的正态分布

Fig.2　The normal distribution of the population sample

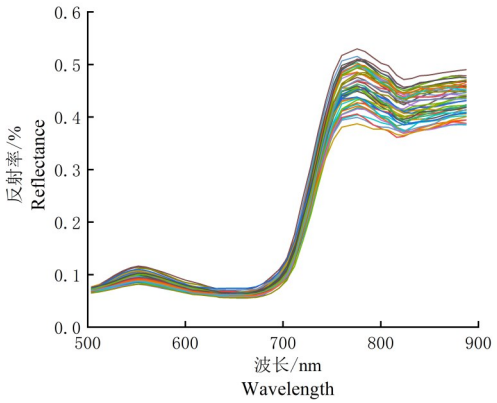

图3　光谱曲线

Fig.3　Spectral curve

2.2　光谱参数筛选

2.2.1　基于相关性分析的光谱参数筛选

水稻叶片SPAD值与原始光谱波段(OR)、经SG平滑处理后的光谱波段(SG)以及原始光谱波

段的一阶微分形式(D1)相关性如图4a所示。宏观上看,原始光谱与经SG平滑处理后的光谱与SPAD相关性都较低,且经SG平滑处理后光谱与SPAD值相关性并没有得到明显提高,而原始光谱的一阶微分形式与SPAD值相关程度有所提高。在663~688、728~736 nm处,原始光谱与SPAD值呈负相关,在503~657、696~721、743~900 nm处两者呈正相关;在672~681、711~729 nm处,经SG平滑处理后的光谱与SPAD值呈负相关,在503~664、687~705、735~900 nm处两者呈正相关;在567~704、831~900 nm处原始光谱的一阶微分形式与SPAD值呈负相关,最大相关系数为0.308,在503~560、711~824 nm处两者呈正相关,最大相关系数为0.319。在以上光谱参数中,仅D1中的部分波段与SPAD值的相关性达到显著性水平。

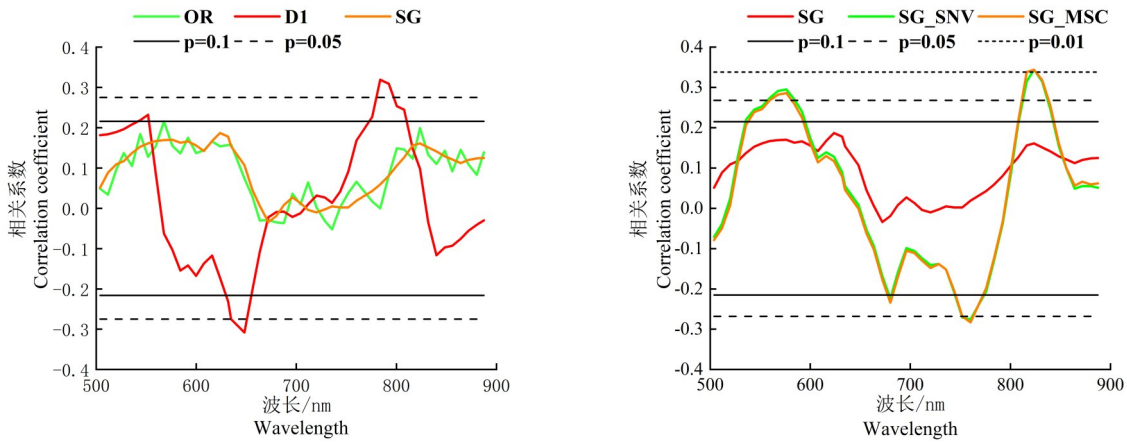

图4 SPAD值与不同光谱变换形式的相关系数

Fig.4 The correlation coefficient of SPAD value with different spectral transformation forms

水稻叶片SPAD值与经SG平滑处理后的光谱波段、经SG_SNV和SG_MSC处理后的光谱波段的相关性如图4b所示。从宏观上来看,在SG平滑基础上进行SNV和MSC处理后的光谱与SPAD值的相关程度与仅经SG平滑处理的光谱相比有所提高,且两者与SPAD值的整体相关程度相似。在503~512、656~793 nm处,经SG_SNV处理后光谱与SPAD值呈负相关,最大相关系数为0.276,在519~649、800~900 nm处两者呈正相关,最大相关系数为0.344;在503~512、648~793 nm处,经SG_MSC处理的光谱与SPAD值呈负相关,最大相关系数为0.283;在519~635、800~900 nm处两者呈正相关,最大相关系数为0.344。在以上光谱参数中,SG_SNV和SG_MSC中部分波段与SPAD值相关性达到显著性水平。

通过对原始光谱以及原始光谱的变换形式和SPAD值的相关性分析,选取了$p<0.1$的波段作为特征波段,结果如表3所示。从D1中选取了10个特征波段,其中达到10%显著水平的波段为544、552、632、776、800和808 nm,达到5%显著水平的波段为635、649、784和792 nm;从经SG_SNV处理后的光谱中选取了15个特征波段,其中达到10%显著水平的波段为536、544、552、592、680和840 nm,达到5%显著水平的波段为560、568、576、584、752、760、816和832 nm,达到1%显著水平的波段为824 nm。从经SG_MSC处理后的光谱中选取了15个特征波段,其中达到10%显著水平的波段为544、552、592、680、801和840 nm,达到5%显著水平的波段为560、568、576、584、752、760和832 nm,达到1%显著水平的波段为816和824 nm。

2.2.2 基于PCA降维结合特征波段的光谱参数筛选

上述筛选出的特征波段的KMO检验结果均大于0.7且通过了Bartlett球形检验,利用PCA算法对这些特征波段进行降维处理。结果由表4可见,其中,特征_D1由10个波段降维到5个主成分,累计贡献率为97.81%;特征_SG_SNV和特征_SG_MSC均由15个波段降维到5个主成分,累计贡献率分别为95.90%和95.49%。

表3　特征波段

Table 3　Characteristic bands

指标 Indicator	D1	SG_SNV	SG_MSC
特征波段/nm	544 552 632 635 649 776 784 792 800 808	536 544 552 560 568 576 584 592 680 752 760 816 824 832 840	544 552 560 568 576 584 592 680 752 760 801 816 824 832 840

表4　降维结果

Table 4　Dimensionality reduction results

光谱指标 Spectral indicators	主成分数 Number of principal components	累计贡献率/% Cumulative contribution rate
特征_D1	5	97.81
特征_SG_SNV	5	95.90
特征_SG_MSC	5	95.49

2.3　水稻叶片SPAD值反演模型建立及检验

分别将相关性分析选取的特征波段和对特征波段进行PCA降维得到的主成分作为自变量(X),水稻叶片SPAD值作为因变量(Y),采用Extra Trees模型进行建模并对比分析,验证基于2种光谱参数对Extra Trees模型预测能力的影响,并优选出研究区SPAD值的最佳预测模型。

采用Extra Trees模型分别对特征光谱和主成分进行建模,其反演精度见表5和表6。由表5和表6可知,构建的2种类型的特征参数结合Extra trees建模都取得了不错的效果,训练集和验证集的R^2均大于0.75,RMSE均小于1.3。在基于特征光谱建模中,最优模型是ET_特征_SG_MSC,训练集的R^2为0.867,RMSE为1.057,验证集的R^2为0.782,RMSE为0.73;在基于主成分建模中,最优模型为ET_PCA_特征_SG_MSC,训练集的R^2为0.85,RMSE为1.03,验证集的R^2为0.825,RMSE为0.984。

表5　基于特征波段建模精度

Table 5　Model accuracy based on characteristic bands

光谱参数 Spectral parameters	训练指标 Training set		验证指标 Validation set	
	R^2	RMSE	R^2	RMSE
D1	0.791	1.26	0.769	1.034
SG_SNV	0.843	1.14	0.754	0.787
SG_MSC	0.867	1.057	0.782	0.73

表6　基于PCA_特征波段建模精度

Table 6　Model accuracy based on PCA_ characteristic bands

光谱参数 Spectral parameters	训练指标 Training set		验证指标 Validation set	
	R^2	RMSE	R^2	RMSE
D1	0.859	0.968	0.793	1.173
SG_SNV	0.849	1.106	0.796	0.839
SG_MSC	0.85	1.03	0.825	0.984

对比2种类型光谱参数的建模效果,结果如图5所示,在特征参数基础上进行PCA降维进一步降低了光谱参数的维度,建模效果相对于直接用特征参数进行建模均有所提高。其中,ET_D1和ET_SG_MSC的R^2分别由0.769和0.782增加到0.793和0.825,提升幅度为3%和5.5%;ET_SG_SNV的R^2由0.754增加到0.796,提升幅度为5.6%。

3　讨论

植物叶片的营养状况和内部的生理生化参数与其自身的光谱特征密切相关,水稻叶片的光谱反射率会随着SPAD值的不同而呈现出不同的光谱响应曲线[26]。在可见光波段,绿色植物的反射光谱主要受叶片色素的影响,吸收作用占主导,反射率较低,因此会出现叶绿素含量越高光谱反射率反而越低的现象;近红外波段的反射光谱主要受植被结构,背景和含水量的影响,与SPAD值的相关性较低。因此本文试验所采集的光谱数据主要包含可见光波段。

高光谱数据含有丰富信息,但原始光谱易受环境、背景及噪声的影响,不可避免会伴随一些与研究参量不相关的信息,影响建模精度。基于此,本文选用了SG平滑、一阶微分变换(DI)、SG平滑与标准正态变换(SG_SNV)、SG平滑与多元散射校正(SG_MSC)对原始光谱进行处理,并将处理后的光谱与SPAD值做相关性分析,将得到的特征波段作为第1种光谱参数;由于高光谱数据维度较大,经过1次光谱参数筛选后的特征参数仍可能伴随着数据冗余、无关信息干扰等问题,而PCA可以通过对数据进行线性变换和压缩的方式实现以较少的主成分保留原数据中绝大部分信息的目的,姚付启等[25]、孙小香等[26]、刘文雅等[27]利用

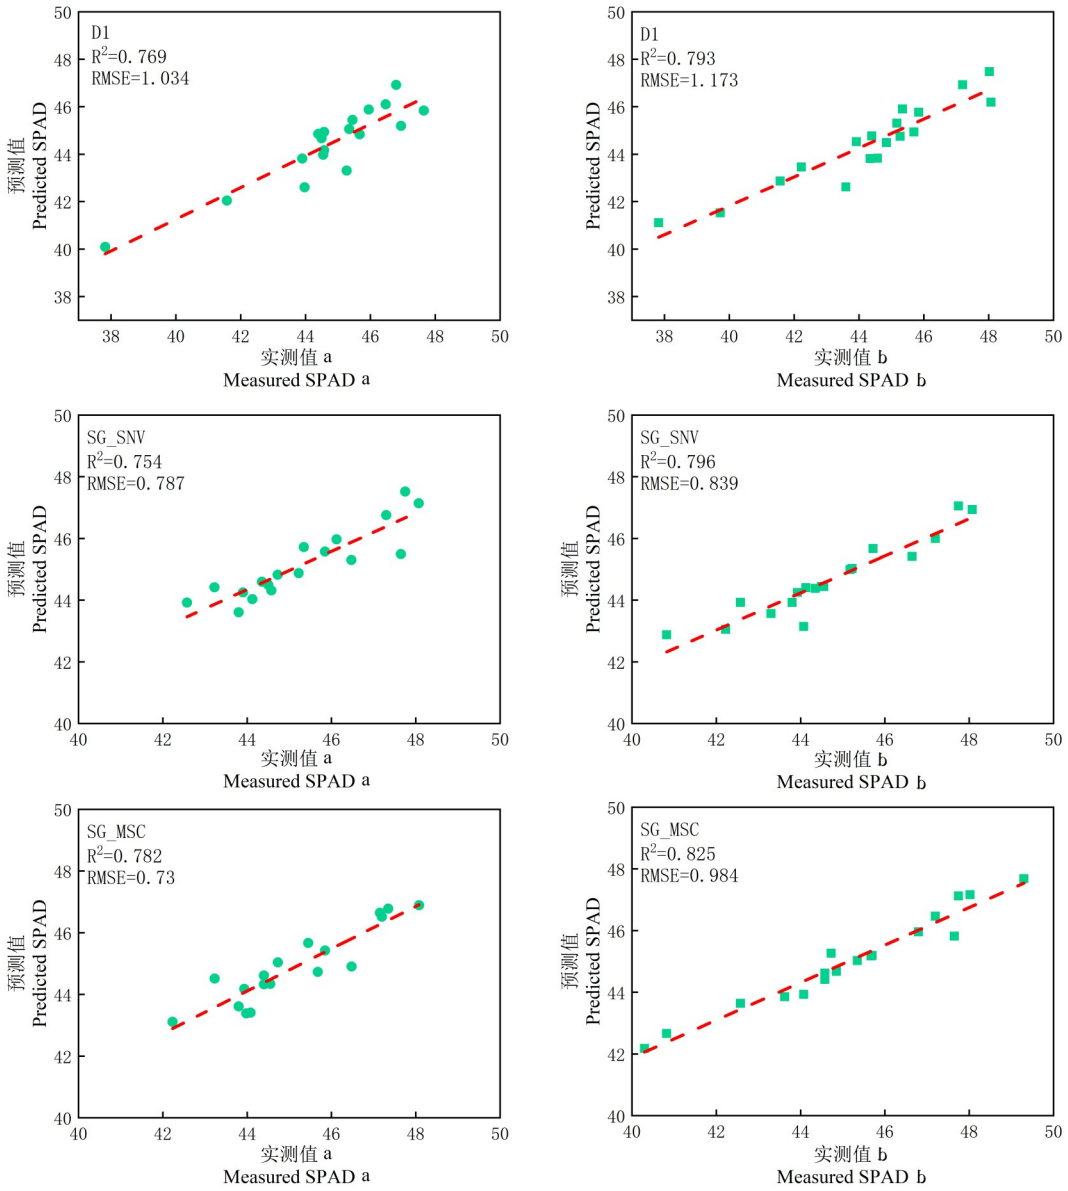

图5 (a)特征波段反演模型散点图;(b)PCA_特征波段反演模型散点图

Fig.5 (a) Characteristic band inversion model scatterplot;(b) PCA_ characteristic band inversion model scatterplot

PCA对原始光谱进行降维,并建模估算了叶绿素含量,都取得了较好的结果。因此在前人的研究基础上,本文在第1种光谱参数的基础上尝试利用PCA算法进行降维,将得到的主成分作为第2种特征参数。对比2种参数的建模效果,发现在特征波段基础上进行PCA降维后建模效果更优,这与尚天浩等[34]利用高光谱估算土壤有机质的研究结果一致。因此,当使用单一方法对光谱筛选后建模效果不佳时,可以尝试组合多种筛选方法,这可以为后续相关研究提供参考。

4 结论

本文以四川省成都市青白江区姚渡镇水稻产区的水稻为研究对象,通过3种预处理方法对水稻叶片原始光谱数据进行处理,并通过相关系数筛选出特征波段作为第1类光谱参数,在第1类光谱参数基础上进行PCA降维得到第2类光谱参数。分别将2类光谱参数代入Extra Trees模型中进行SPAD值的反演,可得出以下结论:

(1)2类光谱参数建立的模型都得到了较好的

结果,决定系数均大于0.75,均方根误差均小于1.3。可为研究区水稻叶片SPAD值的预测提供有效参考。其中模型ET_PCA_特征_SG_MSC精度最高,R^2和RMSE分别为0.825和0.984,是研究区水稻SPAD值的最佳反演模型。

(2)2种光谱参数所建立的模型中,精度最高的都是以SG_MSC预处理为前提筛选出的特征波段和主成分作为输入变量的。说明这种预处理组合方式有效消除了研究区水稻原始光谱中的噪音和散射,为后续的研究提供了良好的基础。

(3)在特征波段基础上进行PCA降维,所建立的模型精度均有所提高,提高幅度最大的模型是ET_特征_SG_SNV,R^2由0.754增加道0.796,提升幅度为5.6%。说明这种方式不仅能有效降低参数维度、减少冗余信息,还保留了特征波段中的重要信息。

参 考 文 献

[1]邓刚,唐志光,李朝奎,等.基于MODIS时序数据的湖南省水稻种植面积提取及时空变化分析[J].国土资源遥感,2020,32(2):177-185.
Deng G, Tang Z G, Li C K, et al. Extraction and analysis of spatiotemporal variation of rice planting area in Hunan Province based on MODIS time series data[J]. Remote Sensing for Land & Resources, 2020, 32(2): 177-185.

[2]徐新刚,赵春江,王纪华,等.新型光谱曲线特征参数与水稻叶绿素含量间的关系研究[J].光谱学与光谱分析,2011,31(1):188-191.
Xu X G, Zhao C J, Wang J H, et al. Study on relationship between new characteristic parameters of spectral curve and chlorophyll content for rice [J]. Spectroscopy and Spectral Analysis, 2011, 31(1): 188-191.

[3]方慧,宋海燕,曹芳,等.油菜叶片的光谱特征与叶绿素含量之间的关系研究[J].光谱学与光谱分析,2007(9):1731-1734.
Fang H, Song H Y, Cao F, et al. Study on the relationship between spectral properties of oilseed rape leaves and their chlorophyll content [J]. Spectroscopy and Spectral Analysis, 2007(9): 1731-1734.

[4]丰明博,牛铮.基于经验模型的Hyperion数据植被叶绿素含量反演[J].国土资源遥感,2014,26(1):71-77.
Feng M B, Niu Z. Chlorophyll content retrieve of vegetation using Hyperion data based on empirical models [J]. Remote Sensing for Land & Resources, 2014, 26(1): 71-77.

[5]陈澜,常庆瑞,高一帆,等.猕猴桃叶片叶绿素含量高光谱估算模型研究[J].西北农林科技大学学报(自然科学版),2020,48(6):79-89,98.
Chen L, Chang Q R, Gao Y F, et al. Hyperspectral estimation model of chlorophyll content in kiwifruit leaves [J]. Journal of Northwest A&F University (Natural Science Edition), 2020, 48(6): 79-89, 98.

[6]徐彩平,刘霞,陈宇炜.浮游植物叶绿素a浓度测定方法的比较研究[J].生态与农村环境学报,2013,29(4):438-442.
Xu C P, Liu X, Chen Y W. Comparison of methods for determination of phytoplankton chlorophyll-a [J]. Journal of Ecology and Rural Environment, 2013, 29(4): 438-442.

[7]薛香,吴玉娥.小麦叶片叶绿素含量测定及其与SPAD值的关系[J].湖北农业科学,2010,49(11):2701-2702,2751.
Xue X, Wu Y E. Chlorophyll content determination and its relationship with SPAD value in wheat [J]. Hubei Agricultural Sciences, 2010, 49(11): 2701-2702, 2751.

[8]艾天成,李方敏,周治安,等.作物叶片叶绿素含量与SPAD值相关性研究[J].湖北农学院学报,2000(1):6-8.
Ai T C, Li F M, Zhou Z A, et al. Relationship between chlorophyll meter readings (SPAD readings) and chlorophyll content of crop leaves [J]. Journal of Hubei Agricultural College, 2000(1): 6-8.

[9]冯伟,郭天财,谢迎新,等.作物光谱分析技术及其在生长监测中的应用[J].中国农学通报,2009,25(23):182-188.
Feng W, Guo T C, Xie Y X, et al. Spectrum analytical technique and its applications for the crop growth detection [J]. Chinese Agricultural Science Bulletin, 2009, 25(23): 182-188.

[10]李粉玲,王力,刘京,等.基于高分一号卫星数据的冬小麦叶片SPAD值遥感估算[J].农业机械学报,2015,46(9):273-281.
Li F L, Wang L, Liu J, et al. Remote sensing estimation of SPAD value for wheat leaf based on GF-1 data [J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(9): 273-281.

[11]姚付启.冬小麦高光谱特征及其生理生态参数估算模型研究[D].杨凌:西北农林科技大学,2012.
Yao F Q. Hyperspectral characteristics and estimating models about physiological ecological parameters of winter wheat [D]. Yangling: Northwest A&F University, 2012.

[12]王树文,赵越,王丽凤,等.基于高光谱的寒地水稻叶片氮素含量预测[J].农业工程学报,2016,32(20):187-194.
Wang S W, Zhao Y, Wang L F, et al. Prediction for nitrogen content of rice leaves in cold region based on hyperspectrum [J]. Transactions of the Chinese Society of Agricultural Engineering, 2016, 32(20): 187-194.

[13]岳学军,全东平,洪添胜,等.柑橘叶片叶绿素含量高光谱无损检测模型[J].农业工程学报,2015,31(1):294-302.
Yue X J, Quan D P, Hong T S, et al. Non-destructive hyperspectral measurement model of chlorophyll content for citrus leaves [J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(1): 294-302.

[14]冯海宽,陶惠林,赵钰,等.利用无人机高光谱估算冬小麦叶绿素含量[J].光谱学与光谱分析,2022,42(11):3575-3580.
Feng H K, Tao H L, Zhao Y, et al. Estimation of chlorophyll content in winter wheat based on UAV hyperspectral [J]. Spectroscopy and Spectral Analysis, 2022, 42(11): 3575-3580.

[15]常潇月,常庆瑞,王晓凡,等.基于无人机高光谱影像玉米叶绿素含量估算[J].干旱地区农业研究,2019,37(1):66-73.

Chang X Y, Chang Q R, Wang X F, et al. Estimation of maize leaf chlorophyll contents based on UAV hyperspectral drone image [J]. Agricultural Research in the Arid Areas, 2019, 37(1):66-73.

[16]尹航,李斐,杨海波,等.基于无人机高光谱影像的马铃薯叶绿素含量估测[J].植物营养与肥料学报, 2021, 27(12):2184-2195.

Yin H, Li F, Yang H B, et al. Estimation of canopy chlorophyll in potato based on UAV hyperspectral images[J]. Journal of Plant Nutrition and Fertilizers, 2021, 27(12):2184-2195.

[17]袁炜楠,许童羽,曹英丽,等.基于主基底分析降维方法的水稻冠层叶片叶绿素含量估算[J].浙江大学学报(农业与生命科学版),2018,44(4):423-430.

Yuan W N, Xu T Y, Cao Y L, et al. Estimation of chlorophyll content in rice canopy leaves based on main base analysis and dimensionality reduction method [J]. Journal of Zhejiang University (Agriculture and Life Sciences), 2018, 44(4):423-430.

[18]宁志强, 刘家祥, 吴越, 等. 基于改进迭代多项式拟合的红外光谱基线校正方法[J]. 激光与光电子学进展, 2020, 57(3): 255-261.

Ning Z Q, Liu J X, Wu Y, et al. Infrared spectrum baseline correction method based on improved iterative polynomial fitting[J]. Laser & Optoelectronics Progress, 2020, 57(3): 255-261.

[19]王丽爱, 马昌, 周旭东, 等. 基于随机森林回归算法的小麦叶片SPAD值遥感估算[J]. 农业机械学报, 2015, 46(1): 259-265.

Wang L A, Ma C, Zhou X D, et al. Estimation of wheat leaf SPAD value using RF algorithmic model and remote sensing data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(1): 259-265.

[20]王圆圆, 李贵才, 张立军, 等. 利用偏最小二乘回归从冬小麦冠层光谱提取叶片含水量[J]. 光谱学与光谱分析, 2010, 30(4): 1070-1074.

Wang Y Y, Li G C, Zhang L J, et al. Retrieval of leaf water content of winter wheat from canopy hyperspectral data using partial least square regression[J]. Spectroscopy and Spectral Analysis, 2010, 30(4): 1070-1074.

[21]第五鹏瑶, 卞希慧, 王姿方, 等. 光谱预处理方法选择研究[J]. 光谱学与光谱分析, 2019, 39(9): 2800-2806.

Diwu P Y, Bian X H, Wang Z F, et al. Study on the selection of spectral preprocessing methods [J]. Spectroscopy and Spectral Analysis, 2019, 39(9): 2800-2806.

[22]吴文强, 常庆瑞, 陈涛, 等. 基于PCA-BP神经网络算法桃树叶片SPAD值高光谱估算[J]. 西北林学院学报, 2019, 34(5): 134-140,224.

Wu W Q, Chang Q R, Chen T, et al. Hyperspectral estimation of peach leaf SPAD value based on PCA-BP neural network algorithm [J]. Journal of Northwest Forestry University,2019, 34(5): 134-140,224.

[23]严志雁, 王芳东, 郭熙, 等. 高光谱估测稻叶SPAD值预处理方法与模型比较[J]. 江西农业大学学报, 2020, 42(6): 1130-1138.

Yan Z Y, Wang F D, Guo X, et al. Comparison of pre-processing methods and models for estimating SPAD of rice leaves by hyperspectrum [J]. Acta Agriculturae Universitatis Jiangxiensis,2020, 42(6): 1130-1138.

[24]陈志超,蒋贵印,张正,等.基于无人机高光谱遥感的春玉米氮营养指数反演[J].河南理工大学学报(自然科学版),2022,41(3):81-89.

Chen Z C, Jiang G Y, Zhang Z, et al. Inversion of nitrogen nutrition index of spring maize based on hyperspectral remote sensing of UAV[J]. Journal of Henan Polytechnic University (Natural Science), 2022,41(3):81-89.

[25]姚付启, 张振华, 杨润亚,等. 基于主成分分析和BP神经网络的法国梧桐叶绿素含量高光谱反演研究[J]. 测绘科学, 2010, 35(1):109-112.

Yao F Q, Zhang Z H, Yang R Y, et al. Research on *Platanus orientalis* L. chlorophyll concentration estimation with hyperspectral data based on BP-artificial neural network and principal component analysis [J]. Science of Surveying and Mapping, 2010, 35(1):109-112.

[26]孙小香, 王芳东, 郭熙, 等. 基于水稻冠层高光谱的叶片SPAD值估算模型研究[J]. 江西农业大学学报, 2018, 40(3): 444-453.

Sun X X, Wang F D, Guo X, et al. The estimation models of rice leaf SPAD value based on canopy spectrum [J]. Acta Agriculturae Universitatis Jiangxiensis, 2018, 40(3): 444-453.

[27]刘文雅,潘洁.基于神经网络的马尾松叶绿素含量高光谱估算模型[J].应用生态学报, 2017, 28(4):1128-1136.

Liu W Y, Pan J. A hyperspectral assessment model for leaf chlorophyll content of Pinus massoniana based on neural network[J]. Chinese Journal of Applied Ecology, 2017, 28(4):1128-1136.

[28]李政.无人机载光谱成像仪对东北寒地水稻生长态势的监测研究[D].长春:长春理工大学,2022.

Li Z. Monitoring research on rice growth in northeast cold region based on UAV-borne spectral imager[D]. Changchun: Changchun University of Science and Technology, 2022.

[29]李晓鹏,胡鹏程,徐照丽,等. 基于四旋翼无人机快速获取大田植株图像的方法及其应用[J]. 中国农业大学学报, 2017, 22(12):131-137.

Li X P, Hu P C, Xu Z L, et al. Method for rapidly acquiring images of field-grown crops using aquad-rotor UAV and its application [J]. Journal of China Agricultural University, 2017, 22(12): 131-137.

[30]黄慧,王伟,彭彦昆,等.利用高光谱扫描技术检测小麦叶片叶绿素含量[J].光谱学与光谱分析,2010,30(7):1811-1814.

Huang H, Wang W, Peng Y K, et al. Measurement of chlorophyll content in wheat leaves using hyperspectral scanning [J]. Spectroscopy and Spectral Analysis, 2010, 30(7):1811-1814.

[31]李静波,张莹,盖荣丽.基于机器学习的星载短波红外CO_2柱浓度估算[J].中国环境科学,2023,43(4):1499-1509.

Li J B, Zhang Y, Gai R L. Estimation of the column concentration of carbon dioxide using spaceborne shortwave infrared spectrometer [J]. China Environmental Science, 2023,43(4):1499-1509.

[32]韩兆迎,朱西存,刘庆,等.黄河三角洲土壤有机质含量的高光谱反演[J].植物营养与肥料学报,2014,20(6):1545-1552.
Han Z Y, Zhu X C, Liu Q, et al. Hyperspectral inversion models for soil organic matter content in the Yellow River Delta [J]. Journal of Plant Nutrition and Fertilizer ,2014, 20(6): 1545-1552.

[33]高林,杨贵军,李长春,等.基于光谱特征与PLSR结合的叶面积指数拟合方法的无人机画幅高光谱遥感应用[J].作物学报,2017,43(4):549-557.
Gao L, Yang G J, Li C C, et al. Application of an improved method in retrieving leaf area index combined spectral index with PLSR in hyperspectral data generated by unmanned aerial vehicle snapshot camera[J]. Acta Agronomica Sinica,2017,43(4):549-557.

[34]尚天浩,毛鸿欣,张俊华,等.基于PCA敏感波段筛选与SVM建模的银川平原土壤有机质高光谱估算[J].生态学杂志,2021,40(12):4128-4136.
Shang T H, Mao H X, Zhang J H, et al. Hyperspctral estimation of soil organic matter content in Yinchuan Plain, China based on PCA sensitive band screening and SVM modeling[J]. Chinese Journal of Ecology,2021,40(12):4128-4136.

Inversion method of rice leaf SPAD values based on UAV hyperspectral imagery

Xie Dong[1], He Jing[1*], He Jiachen[1], Wang Bin[1], Lin Yuanyang[1], Liu Gang[1,2]

(*1.College of Earth Sciences, Chengdu University of Technology, Chengdu 610059, China; 2.State Key Laboratory of Geological Hazard Prevention and Geoenviromental Protection, Chengdu University of Technology, Chengdu 610059, China*)

Abstract:[Objective]Achieving efficient and non-destructive monitoring of chlorophyll content in rice through UAV hyperspectral imagery is an important means for the development of modern precision agriculture. This study investigated different preprocessing methods and their combinations for raw spectral data of rice leaves, constructed models using different spectral parameters, and obtained the optimal inversion model for relative chlorophyll content (SPAD value) of rice leaves in the study area. This research aimed to provide references for efficient and non-destructive monitoring of chlorophyll content in rice leaves. [MethodsThe rice fields in Yaodu Town, Qingbaijiang District, Chengdu City, Sichuan Province were selected as the research object. The SPAD value of rice leaves and hyperspectral reflectance in the range of 500-900 nm were measured. Different preprocessing methods, including first order differentiation (D1), Savitzky-Golay convolution smoothing (SG smoothing), standard normal transformation (SNV), multiple scattering correction (MSC), and their combinations were applied to the original reflectance data. The characteristic bands with $p<0.1$ were selected as the first spectral parameter. Principle component analysis (PCA) was then conducted on the basis of the characteristic bands to obtain the second set of spectral parameters. These two parameters were used as input variables of the Extra Trees models to establish inversion model of rice chlorophyll content in the study area. [Results]Compared with models constructed using feature bands selected based on correlation coefficients, models constructed with PCA for dimensionality reduction of the feature bands achieved higher modeling accuracy. Specifically, R^2 values for ET_D1 and ET_SG_MSC increased from 0.769 and 0.782 to 0.793 and 0.825, representing improvements of 3% and 5.5%, respectively. The R^2 value for ET_SG_SNV increased from 0.754 to 0.796, showing an improvement of 5.6%. Among the models, ET_PCA_ features _SG_MSC demonstrated the highest accuracy, with R^2 and RMSE values of 0.825 and 0.984, respectively, making it the optimal inversion model for SPAD values of rice leaves in the study area. [Conclusion]The results of this study provided a reference and basis for achieving efficient and accurate monitoring of chlorophyll content in rice leaves.

Keywords:Rice, Chlorophyll, Hyperspectral, Correlation coefficient, Principal component analysis, Extra Tress

(编辑:韩志强)