doi:10.6041/j.issn.1000-1298.2023.09.033

基于分数阶微分和最优光谱指数的大豆叶面积指数估算

向友珍[1,2]　王　辛[1,2]　安嘉琪[1,2]　唐子竣[1,2]　李汪洋[1,2]　史鸿棹[1,2]

(1.西北农林科技大学旱区农业水土工程教育部重点实验室,陕西杨凌 712100;
2.西北农林科技大学水利与建筑工程学院,陕西杨凌 712100)

摘要:高光谱遥感技术可对作物生长状况进行无损、高效地监测,是推动现代精准农业发展的必要手段。以不同施氮水平与覆膜处理下的开花期大豆叶面积指数(Leaf area index,LAI)为研究对象,对原始开花期大豆高光谱反射率数据进行 0~2 阶微分变换处理(步长 0.5),并筛选出各阶光谱指数中与开花期大豆 LAI 相关性最高的指数作为最优光谱指数进行输入,采用支持向量机(Support vector machine, SVM)、随机森林(Random forest,RF)、遗传算法优化的 BP 神经网络(BP neural network optimized by genetic algorithm, GA-BP)3 种机器学习方法构建大豆 LAI 预测模型。结果表明:0~2 阶光谱指数与大豆 LAI 相关系数平均值分别为 0.616、0.657、0.666、0.669、0.658,相比于原始与整数阶高光谱反射率,分数阶微分变换处理后的高光谱反射率构建的光谱指数与开花期大豆 LAI 具有更强的相关性;相关系数平均值最高的 1.5 阶微分处理最优光谱指数波长组合分别为:TVI(687 nm,754 nm)、DI(687 nm,754 nm)、SAVI(728 nm,738 nm)、RI(687 nm,744 nm)、NDVI(620 nm,653 nm),其余各阶最优光谱指数组合对应波段也集中分布于红边波段(680~760 nm);随着微分阶数提高,光谱指数与大豆 LAI 的相关性和构建的预测模型的精度均呈先升后降的趋势;当输入变量相同时,RF 为 3 种机器学习模型中的最佳建模方法。经过综合比较,以 1.5 阶微分处理得到的最优光谱指数组合作为输入数据,基于 RF 构建的大豆 LAI 预测模型取得了最高的精度,验证集的决定系数 R^2 为 0.880,均方根误差(RMSE)为 0.320 0 cm^2/cm^2,标准均方根误差(NRMSE)为 10.354%,平均相对误差(MRE)为 9.572%。研究结果可为提高大豆 LAI 高光谱反演精度与指导精准农业生产提供理论参考。

关键词:大豆;叶面积指数;高光谱;分数阶微分;最优光谱指数

中图分类号:S252　　**文献标识码**:A　　**文章编号**:1000-1298(2023)09-0329-14　　**OSID**:

Estimation of Leaf Area Index of Soybean Based on Fractional Order Differentiation and Optimal Spectral Index

XIANG Youzhen[1,2]　WANG Xin[1,2]　AN Jiaqi[1,2]　TANG Zijun[1,2]　LI Wangyang[1,2]　SHI Hongzhao[1,2]

(1. *Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas, Ministry of Education, Northwest A&F University, Yangling, Shaanxi* 712100, *China*
2. *College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi* 712100, *China*)

Abstract: Hyperspectral remote sensing crop growth monitoring technology, an essential instrument for developing contemporary precision agriculture, is characterized by non-destructiveness and real-time effectiveness. Taking leaf area index (LAI) of soybean at flowering stage under different levels of N application and mulching treatment as research object, the raw data for the hyperspectral reflectance of the soybean canopy were pretreated by using the 0~2 order differential transform processing (step 0.5). Based on five sets of pretreatment reflectance data, the optimum spectral index with a high correlation to the LAI of soybean at the blooming stage was the input data. And the support vector machine (SVM), random forest (RF), and BP neural network optimized by genetic algorithm (GA-BP) were used to construct the soybean LAI prediction model. The results showed that compared with the integer order and the raw hyperspectral reflectance, the spectral indices built from the fractional order differential preprocessed hyperspectral reflectance correlated better with the soybean LAI. The corresponding bands of different orders of optimal spectral indices concentrated in the red-edge band. The correlation between the

收稿日期:2022-11-22　修回日期:2022-12-28

基金项目:国家自然科学基金项目(52179045)

作者简介:向友珍(1973—),女,副教授,博士生导师,主要从事遥感技术在农业水土工程应用研究,E-mail:Youzhenxiang@nwsuaf.edu.cn

spectral index and soybean LAI was increased and then decreased as the differential order was increased, and the accuracy of the prediction model showed the same pattern. When the input data were the same for all three machine learning techniques, the model created by RF had the highest accuracy. A thorough analysis determined that the soybean LAI prediction model built by using RF had the highest accuracy of prediction when the input variable was the 1.5-order differential optimal spectral index. The R^2 of the model validation set was 0.880, the RMSE was 0.320 0 cm^2/cm^2, the NRMSE was 10.354% and the MRE was 9.572%. The research result can help advance the development of precision agricultural production by offering theoretical references for enhancing the inversion accuracy of soybean LAI hyperspectral prediction models.

Key words: soybean; leaf area index; hyperspectrum; fractional order differentiation; optimal spectral index

0 引言

大豆是世界农产品贸易中最重要的油脂产品之一,我国的大豆消费市场广阔,但大豆的自给率却不到15%,其产量与品质直接影响着我国粮食安全水平[1]。大豆开花期生长状况对于大豆后续生殖生长与最终产量形成有着重要影响[2]。单位耕地面积上作物叶片总面积与耕地面积之比[3]即为叶面积指数(Leaf area index,LAI),是一种描述植物冠层结构与生长状况的关键植物生理参数[4-5]。科学高效地获取大豆开花期LAI对开花期大豆的生长状态评估与产量预测具有重要意义[6-7]。

采用传统方法对LAI进行直接测定费时、费力、成本较高且具有破坏性与不可恢复性。高光谱遥感农作物生长监测技术因其光谱分辨率高、连续波段多[8]的特点,可对田间作物LAI进行实时、高效测定[9-10]。现有研究大多利用原始冠层高光谱反射率数据进行LAI反演模型构建,但直接采用原始高光谱反射率数据构建的LAI反演模型预测效果并不理想[11]。有学者引入整数阶微分变换方法对原始高光谱反射率数据进行处理,在一定程度上消除了光谱数据的背景噪声,提高了建模精度[12];但也有研究表明1阶、2阶乃至更高阶的整数阶微分变换方法忽略了光谱信息的连续性与渐变性[13],在消除背景噪声的同时也会造成光谱特征的丢失[14]。在土壤含盐量的反演研究中,已有学者发现相较于整数阶微分变换,分数阶微分变换处理得到的光谱反射率与盐分指标具有更强的相关性[15]。作为整数阶微分的数学拓展,分数阶微分变换可以突出光谱信息的细微变化,增强部分较弱的光谱特征,提高光谱反射率信噪比[16]。

光谱指数是不同敏感波段的线性或非线性组合[17],与单一波段相比,根据绿色植被特有光谱特征选择的波段构建的高光谱植被指数包含的作物生长信息更为充分[18]。在LAI预测模型构建过程中,适宜的波段组合选择能有效提高模型精度[19],因此构建高光谱植被指数时的波段优选也是重要的研究内容[20]。传统光谱指数多采用2个或多个固定波段进行构建,作物种类与生长环境的变化会改变作物的光谱特征,固定波段限制了光谱指数对于光谱信息的充分提取从而影响预测模型的拟合优度[21]。采用相关矩阵法在全部可用波段内筛选与大豆LAI相关性高的波段进行最优光谱指数构建,可有效解决光谱特征易受作物本身生理信息差异影响的问题,显著促进了光谱信息的利用[22]。高光谱遥感技术对于光谱的划分更为精细,提供了在所有可用光谱波段范围内选择与LAI有强相关性的波段进行最优光谱指数构建的可能。

本文以不同施氮水平与覆膜处理下的开花期大豆LAI为研究对象,对原始高光谱反射率进行0~2阶分数阶微分变换(步长0.5),采用相关矩阵法在350~1 830 nm波段内筛选与大豆LAI相关性最高的波段构建5组、共计25个最优光谱指数。在此基础上采用支持向量机(Support vector machine,SVM)、随机森林(Random forest,RF)、遗传算法优化的BP神经网络(BP neural network optimized by genetic algorithm,GA-BP)构建开花期大豆LAI预测模型,并讨论不同微分阶数与不同机器学习方法的组合对于大豆LAI预测模型精度的影响,以期为更加准确、快速地获取开花期大豆LAI提供理论参考。

1 材料与方法

1.1 试验区概况

两年大豆田间试验在西北农林科技大学旱区农业水土工程教育部重点实验室节水灌溉试验站试验田(壤土)进行。试验站坐标:108°24′E、34°20′N(见图1),海拔524.7 m,属于暖温带季风半湿润气候区,降雨集中分布于7—9月,多年平均降水量约580 mm,多年平均温度约为12.9℃。

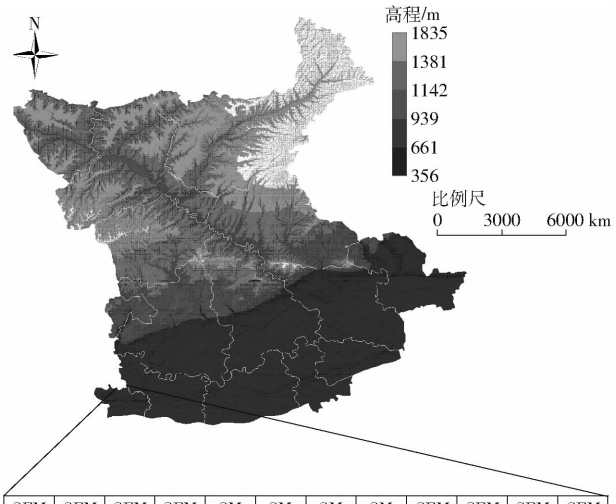

SFM N3	SFM N2	SFM N1	SFM N4	SM N3	SM N2	SM N4	SM N1	SFM N1	SFM N4	SFM N2	SFM N3
NM N2	NM N4	NM N1	NM N3	SM N1	SM N4	SM N2	SM N3	FM N2	FM N4	FM N1	FM N3
			CK	NM N3	NM N4	NM N1	NM N2	FM N3	FM N1	FM N2	FM N4

图 1　试验小区布设示意图

Fig. 1　Experimental design

本试验共设置了 4 个施氮水平：N1：30 kg/hm^2、N2：60 kg/hm^2、N3：90 kg/hm^2、N4：120 kg/hm^2，4 种覆盖处理：SM：秸秆覆盖、FM：农膜覆盖、SFM：秸秆 + 农膜覆盖、NM 无覆盖处理。秸秆覆盖量为 6 000 kg/hm^2，FM 与 SFM 处理采用起垄覆盖膜侧播种方式，于试验小区内起底两条宽 40 cm、高 25 cm 的垄，用 60 cm 宽的地膜覆盖垄面，大豆播种于膜侧 5 cm 处，行距 50 cm。试验以平作不施氮处理（CK）为对照，各处理随机排列，两次重复，试验小区面积为 2.5 m × 6 m = 15 m^2，共计 33 个小区。试验用缓释氮肥（SNF）、钾肥（K_2O，30 kg/hm^2）、磷肥（P_2O_5，30 kg/hm^2）作为基肥，在播前一次性施入。试验用大豆品种为山宁 17 号，分别于 2021 年 6 月 17 日与 2022 年 6 月 9 日播种，于 2021 年 9 月 30 日与 2022 年 9 月 28 日进行收获，大豆开花期分别为：2021 年 7 月 28 日—8 月 24 日与 2022 年 7 月 23 日—8 月 20 日，大豆生育期内未出现明显病虫害。

1.2　数据采集

于两年试验中大豆开花期（2021 年 8 月 5 日与 2022 年 8 月 10 日）进行 LAI 的测定与光谱数据的采集，采集日天气晴朗，光照稳定，两年试验共计获得 LAI 与高光谱反射率样本 66 组。数据如表 1 所示。

1.2.1　大豆冠层高光谱数据采集

分别于 2021 年 8 月 5 日和 2022 年 8 月 10 日 10：40—13：00 进行试验小区大豆冠层高光谱反射率数据采集，该时段光照充足，测量光谱信息多，误差较小。试验用高光谱测量仪器为美国 ASD（Analytical Spectral Devices）公司生产的 Field Spec4 型可见光/近红外便携式地物高光谱仪[23]，仪器波段 350 ~ 1 830 nm，其中，350 ~ 1 000 nm 光谱分辨率为 3 nm，采样间隔为 1.4 nm；1 000 ~ 1 830 nm 分辨率为 10 nm，采样间隔为 2 nm，仪器自动将采样数据插值为 1 nm 间隔输出，视场角 25°。

表 1　大豆开花期 LAI 数据统计

Tab. 1　Statistics of leaf area index of soybean at flowering stage

统计指标	叶面积指数 LAI/(cm^2·cm^{-2})
最大值	5.56
最小值	1.02
平均值	3.09
标准差	0.96
样本量	66
变异系数/%	0.31

在高光谱数据采集前对光谱仪进行预热、优化处理并在 1 min 内完成参考板检验和比对，在前一试验小区高光谱反射率数据采集结束后，后一试验小区高光谱反射率数据采集开始前进行参考板校正。于每个试验小区中选取长势均衡的作物冠层，试验人员手持光谱传感器探头，距作物冠层顶部 75 cm 垂直向下采集数据，每次共采集记录 10 次高光谱反射率数据，依据“3σ”原则[24]剔除异常值后以余下光谱波段反射率的均值作为各小区最终高光谱反射率数据。

1.2.2　大豆 LAI 数据采集

田间大豆 LAI 实测使用美国 LI - COR LAI - 2200C 型植物冠层分析仪测定。在高光谱反射率数据影像采集的当天进行大豆 LAI 数据采集。在 33 个试验小区内各随机进行 6 次大豆 LAI 数据采集，以其均值作为各试验小区的实测值。

1.3　光谱数据处理

本研究采用 Savitzky - Golay（SG）平滑法对光谱数据进行降噪处理，采用 G - L 分数阶微分（Fractional order differentiation，FOD）算法对高光谱反射率数据进行 0 ~ 2 阶（步长 0.5）分数阶微分变换。G - L FOD 算法可将传统的整数阶微分拓展为任意阶微分，可以更加充分地解释数据的细微变化与整体性信息，本试验中高光谱反射率数据的 α 阶微分公式为[25]

$$\frac{\mathrm{d}^{\alpha}f(x)}{\mathrm{d}x^{\alpha}} \approx f(x) + (-\alpha)f(x-1) + \frac{(-\alpha)(-\alpha+1)}{2}f(x-2) + \cdots + \frac{\Gamma(-\alpha+1)}{n!\,\Gamma(-\alpha+n+1)}f(x-n)$$

式中 x——对应点的值

α——分数阶微分阶

Γ——Gamma 函数

n——微分上下限之差,阶数为 0,则表示未经预处理

光谱数据预处理、植被指数计算均在 Matlab 2018 中完成,使用 Origin 2021 进行图形绘制。

1.4 光谱指数选择与构建

选取 7 种光谱指数(表 2):比值植被指数(Ratio index,RI)和三角植被指数(Triangular vegetation index,TVI)与植物的叶绿素含量、LAI 具有强相关性,但当植被较茂密时其灵敏度会降低[23];改进红边比值指数(Modified red edge simple ratio,mSR)与改进红边归一指数(Modified normalized difference index,mNDI)可对叶片的镜面发射效应进行优化,对于叶片的变化较为敏感;差值植被指数(Difference index,DI)、归一化植被指数(Normalized difference vegetation index,NDVI)和土壤调节植被指数(Soil-adjusted vegetation index,SAVI)均可反映植物冠层的背景影响并消除部分辐射误差[26]。

表 2 研究选取光谱指数

Tab. 2 Spectral indices selected for the study

选取指数	计算式	文献序号
比值植被指数(RI)	R_i/R_j	[23]
三角植被指数(TVI)	$0.5[120(R_i-R_{550})-200(R_j-R_{550})]$	[23]
改进红边比值指数(mSR)	$(R_i-R_{455})/(R_j-R_{455})$	[26]
改进红边归一指数(mNDI)	$(R_i-R_j)/(R_i+R_j-2R_{455})$	[26]
差值植被指数(DI)	R_i-R_j	[26]
土壤调节植被指数(SAVI)	$(1+0.16)\frac{R_i-R_j}{R_i+R_j+0.16}$	[26]
归一化植被指数(NDVI)	$(R_i-R_j)/(R_i+R_j)$	[26]

注:R_i、R_j 为任意波段处的反射率,R_{455}、R_{550} 为 455 nm 与 550 nm 波长处的光谱反射率。

1.5 模型构建

本研究以构建的不同阶最优光谱指数组合作为输入变量,采用 SVM、RF、GA-BP 共 3 种机器学习方法进行建模,对开花期的大豆 LAI 进行回归预测,训练集与验证集数据比例为 2∶1,机器学习模型多次预测拟合结果的平均值作为本试验中的最终模型拟合结果。

1.5.1 支持向量机

支持向量机(SVM)是一种以高斯核和多项式核作为基核函数,采用梯度下降算法进行权重系数优化的二分类机器学习算法[27],具有良好的泛化能力和鲁棒性,没有过拟合缺陷,在模式识别、分类以及小样本回归分析中得到了广泛应用[28]。根据最小交叉验证误差的原则,本研究中 SVM 模型的惩罚系数 C 与 γ 分别为 20 与 0.02。

1.5.2 随机森林

随机森林(RF)是一种基于 Bagging 模型思想的积分模型。由于其简单、方便的特点,已广泛应用于各种回归和预测问题中。RF 模型对每棵树的结果进行加权平均以达到最终输出,因此该模型的实现需要构建大量的决策树,并通过交换和改变协变量来构建一组决策树以提高预测性能[29-30]。随机森林需要在放回样本得到的 N 个采样训练-测试集上训练 N 棵决策树,基于随机森林模型的回归,将多棵决策树的平均预测结果作为最终结果。在决策树模型内进行训练-测试时,需要遍历每个特征和每个方法以有效地确定最优决策树数量,经过多次训练与误差分析,RF 模型中的决策树数量确定为 100。

1.5.3 遗传算法优化的 BP 神经网络

BP 神经网络(Back propagation neural network)是采用逆向传播算法进行训练的一种多层前馈型网络,本质上是基于梯度下降的一种迭代学习算法,存在易陷入局部极小点、收敛速度慢、接近最优解时可能产生振荡等缺陷[31]。

遗传算法(Genetic algorithrn,GA)是以自然选择和遗传理论为基础,将生物进化过程中适者生存原则与群体内部染色体的随机信息交换机制相结合产生的一种全局寻优搜索算法,它不依赖梯度信息,特别适用于高度非线性、不连续等复杂系统的优化问题,广泛应用于机器学习、人工神经网络训练、模式识别等复杂优化问题[32-33]。遗传算法可对 BP 神经网络的初始权值进行优化,替代梯度下降调节网络权值和阈值的过程,解决 BP 算法由于梯度下降引起的难题。本研究采用遗传算法对 BP 神经网络进行优化,遗传算法的初始种群数量为 5,遗传代数设为 50,交叉概率为 0.4%,变异概率为 0.05%;种群经优化后 BP 神经网络输入层节点个数为 5,隐含层节点个数为 5,输出层节点个数为 1,最大迭代次数为 1 000,训练目标为 1×10^{-6}。

1.6 模型精度验证

(1)模型评价指标

模型拟合结果采用决定系数(R^2)、均方根误差(RMSE)、标准均方根误差(NRMSE)与平均相对误差(MRE)进行评价[34-35],R^2 越接近 1,说明模型的预测精度越高;RMSE 与 MRE 越小,说明模型的性能更稳定,预测结果也更为集中,NRMSE 小于 10% 时,模型的预测值与实测值的一致性表现为极好;NRMSE 为 10% ~20% 时,模型的预测值与实测值的一致性表现为较好;NRMSE 为 20% ~30% 时,模

型的预测值与实测值的一致性表现为一般；NRMSE 大于 30% 时，模型的预测值与实测值的一致性表现为较差。

（2）显著性检验

参考自相关性系数检验表，当自由度（即样本量）为 66，相关系数大于 0.310，达到极显著相关水平（$P < 0.01$）；当自由度为 44，相关系数大于 0.376，达到极显著相关水平（$P < 0.01$）；当自由度为 22 时，相关系数大于 0.515，达到极显著相关水平（$P < 0.01$）。

2　结果与分析

2.1　0 ~ 2 阶微分光谱曲线

本研究采用 FOD 算法对原始高光谱反射率数据进行 0 ~ 2 阶（步长 0.5）分数阶微分变换处理，图 2 为平均后的各阶高光谱反射率曲线。大豆原始高光谱反射率曲线呈现出典型的绿色植物反射特征，在绿光波段 550 nm 左右有 1 个明显的反射峰，这是因为植物对于绿光具有较强的反射作用；由于植物对红光的强吸收性，反射率曲线在红光波段 680 nm 左右出现了 1 个吸收谷；在波段 680 ~ 760 nm 光谱反射率急增，出现一段反射陡坡，形成了绿色植被特有的光谱特征——红边。由于植被含水率的影响，1 300 ~ 1 830 nm 光谱反射率快速下降，1 400 nm 左右出现了水汽波段的吸收峰。分数阶微分处理可降低光谱反射率噪声，突出反射率曲线中的细微变化，并保留植物的光谱特征，随着微分阶数增加，各波段对应的光谱反射率渐趋于 0，标准差也逐渐减小，红边特征波段在各阶反射率曲线中均具有较高的反射率。

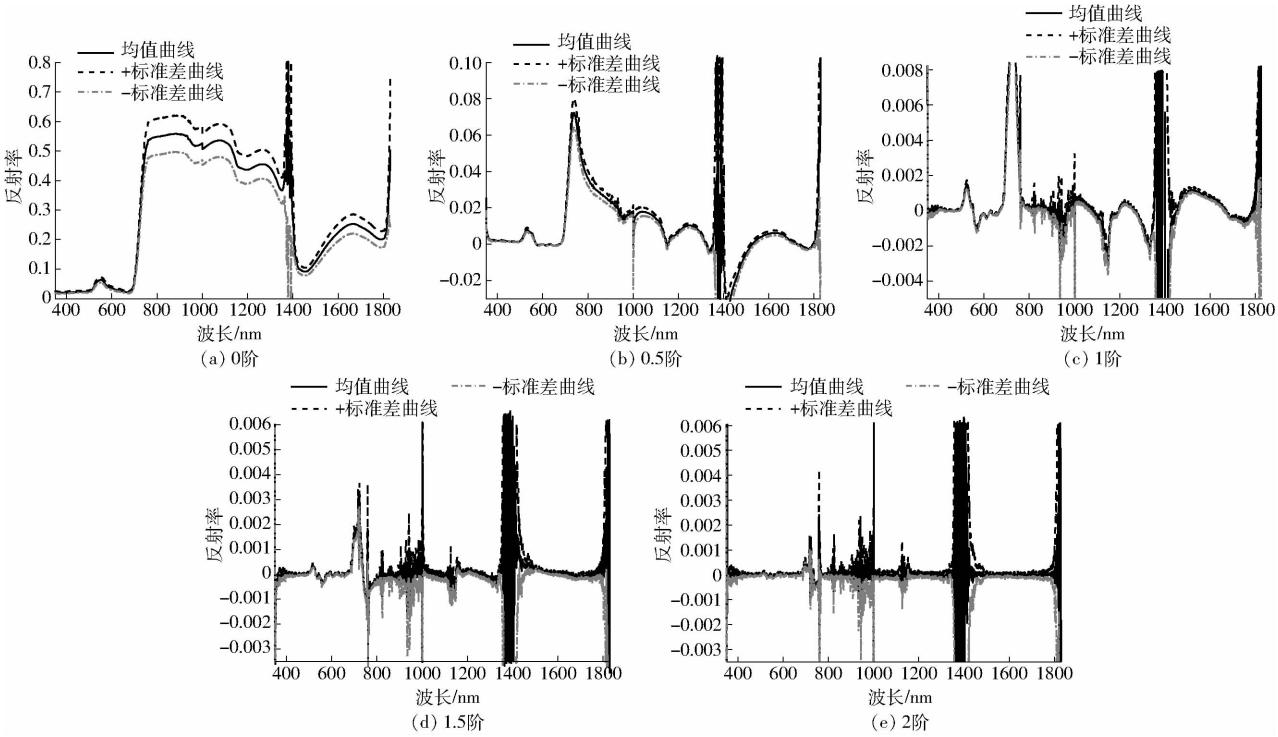

图 2　0 ~ 2 阶微分光谱反射率曲线

Fig. 2　Spectral curves after FOD of order 0 to 2

2.2　光谱指数构建与最优光谱指数波段组合提取

为更充分地利用高光谱反射率数据所含信息，选取了 7 个典型光谱指数。首先对 0 ~ 2 阶分数阶微分处理后的高光谱反射率的所有波段进行逐波段光谱指数计算，再通过相关矩阵法与大豆 LAI 进行相关性分析，以最大相关系数所在的 i 和 j 波长进行不同阶光谱指数构建，并在 7 个光谱指数中选取与大豆 LAI 相关性最高的 5 个指数作为最优光谱指数组合。绘制相关性矩阵图，如图 3 ~ 6 所示，从蓝到红表示光谱指数与大豆 LAI 的相关性由高负相关到高正相关。

图 3 ~ 6 为经分数阶微分处理，0 ~ 2 阶分数阶微分高光谱植被指数与大豆 LAI 的相关矩阵图，各阶光谱指数大豆 LAI 的相关系数均大于 0.310（$P \leqslant 0.01$），达到极显著相关水平，说明本研究选取的 7 个光谱指数均可用于预测开花期大豆 LAI。0 ~ 2 阶光谱指数与大豆 LAI 相关系数的平均值分别 0.616、0.657、0.666、0.669、0.658，分数阶微分处理后计算得出的最优光谱指数与大豆 LAI 的相关性与原始光谱指数相比得到显著提高。1.5 阶微分处理下，与大豆 LAI 相关系数最高的是 TVI，相关系数为 0.755，波长组合坐标为（687 nm，754 nm），各光谱指数与大豆 LAI 的相关系数由高到低排列为：

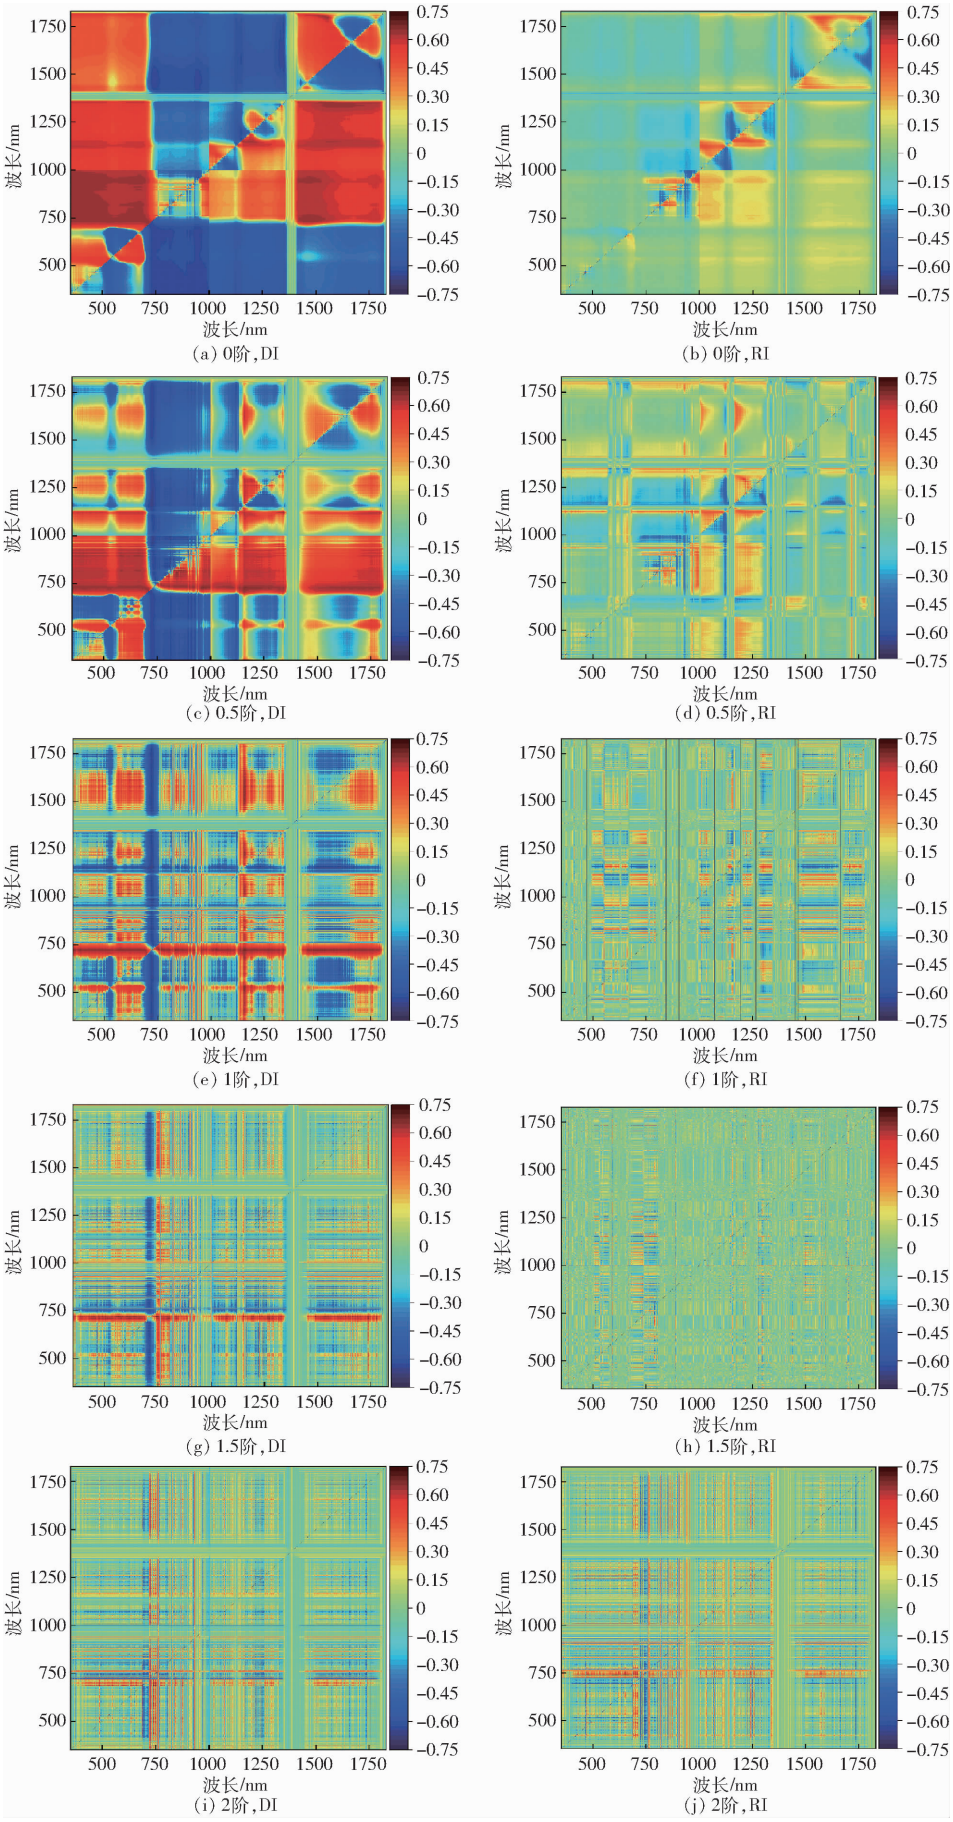

图 3 0～2 阶微分下 DI、RI 与开花期大豆 LAI 相关矩阵图

Fig. 3 Correlation matrix of DI and RI with LAI under 0～2 order differential

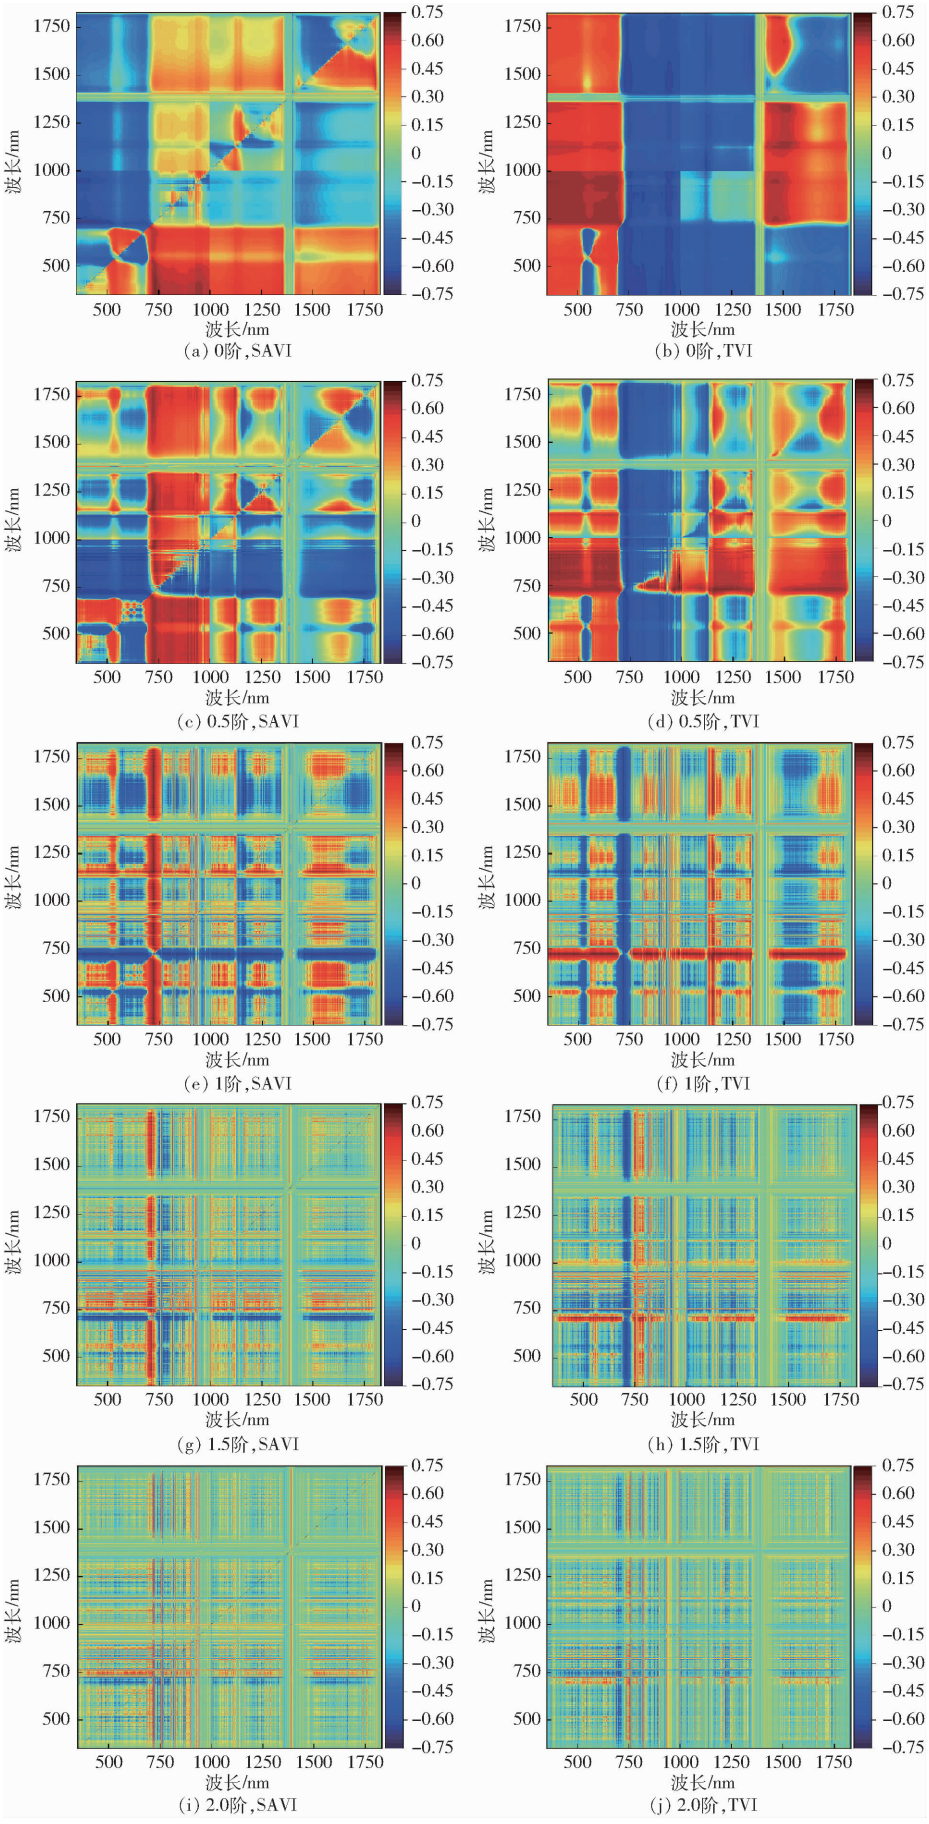

图 4　0 ~ 2 阶微分下 SAVI、TVI 与开花期大豆 LAI 相关矩阵图

Fig. 4　Correlation matrix of SAVI and TVI with LAI under 0 ~ 2 order differential

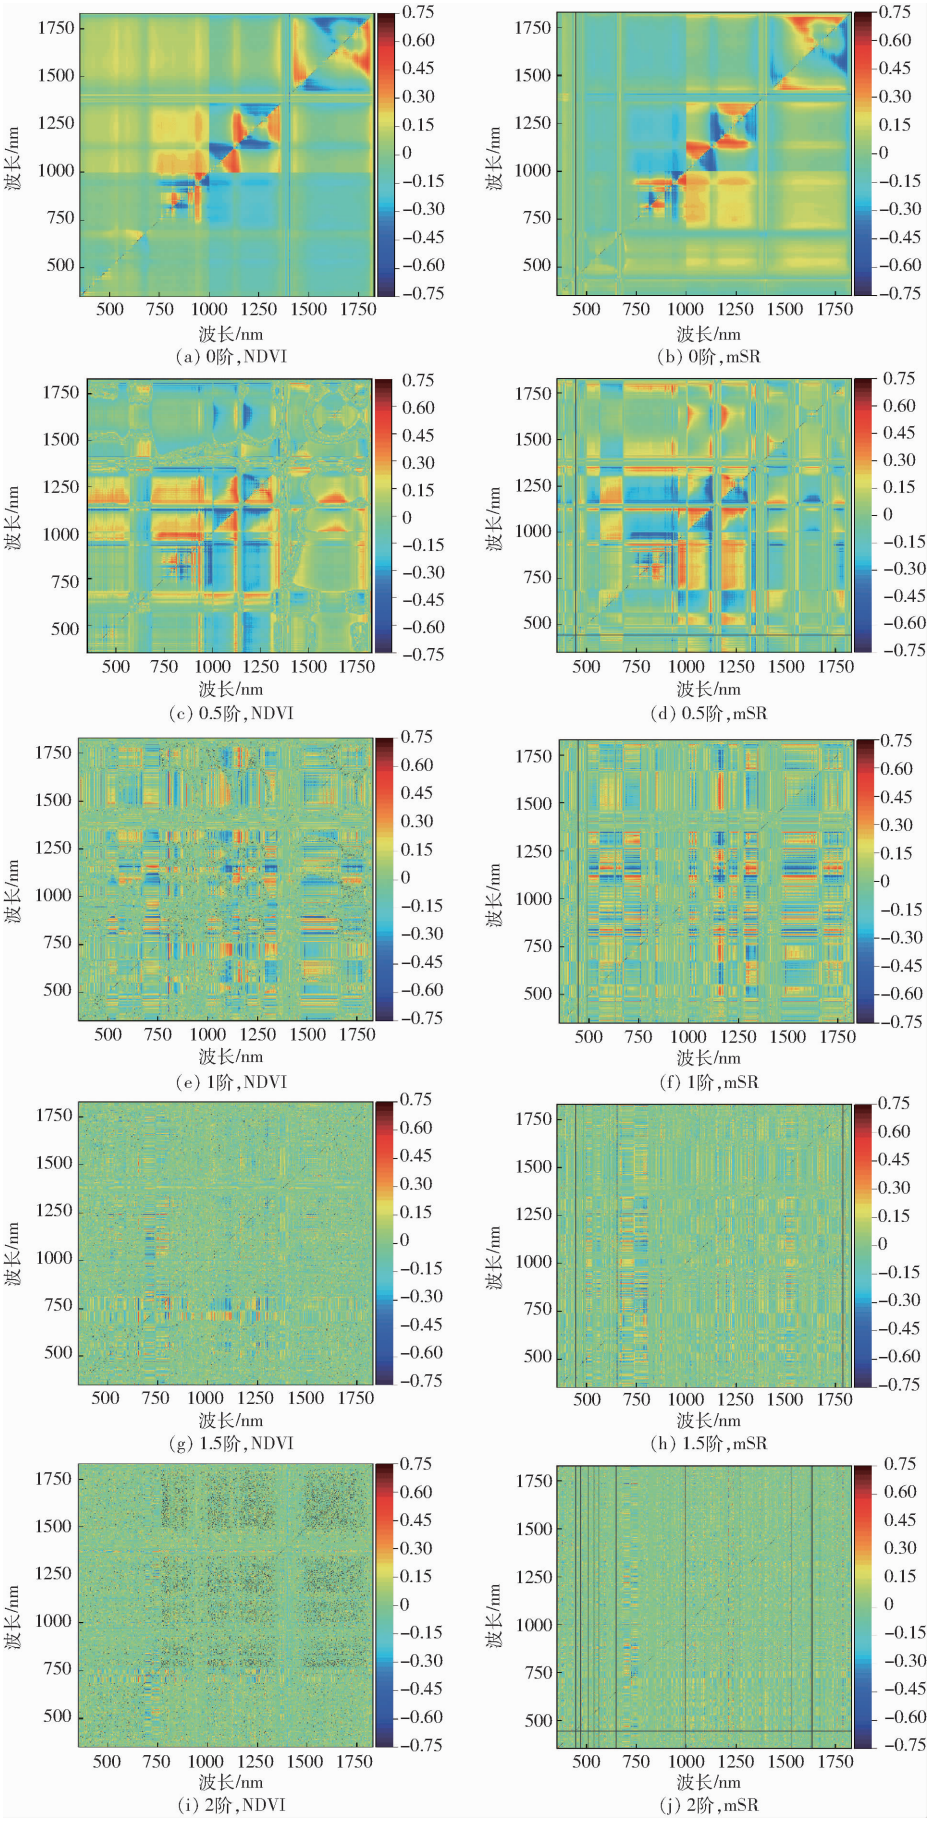

图 5 0 ~ 2 阶微分下 NDVI、mSR 与开花期大豆 LAI 相关矩阵图

Fig. 5 Correlation matrix of NDVI and mSR with LAI under 0 ~ 2 order differential

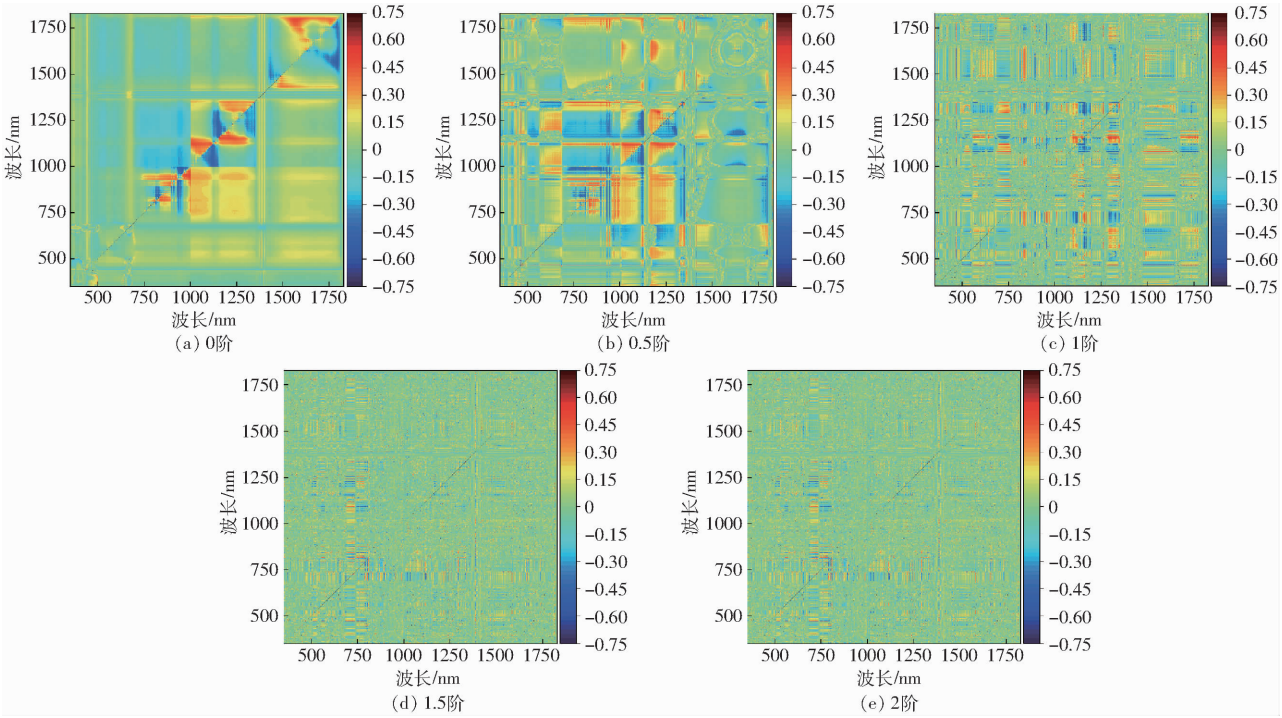

图 6　0～2 阶微分下 mNDI 与开花期大豆 LAI 相关矩阵图

Fig. 6　Correlation matrix of mNDI with LAI under 0～2 order differential

TVI、DI、SAVI、RI、NDVI、mNDI、mSR。在上述 7 个光谱指数中选取 5 个相关系数最高的光谱指数 TVI、DI、SAVI、RI、NDVI 作为最优光谱指数组合，其对应波段组合：(687 nm, 754 nm)、(687 nm, 754 nm)、(728 nm, 738 nm)、(687 nm, 744 nm)、(620 nm, 653 nm)为最优光谱指数波段组合。其余分数阶微分最优光谱指数组合与最优光谱指数组合对应波段见表 3。

表 3　不同微分阶数下的最优光谱指数波长组合

Tab. 3　Optimal vegetation index wavelength combinations at different differential orders

微分阶数	光谱指数	相关系数	波长位置 (i,j)/nm	最优光谱指数组合	微分阶数	光谱指数	相关系数	波长位置 (i,j)/nm	最优光谱指数组合
0	DI	0.678**	(717,730)	DI、SAVI、TVI、mNDI、NDVI	1.5	DI	0.741**	(687,754)	DI、SAVI、TVI、RI、NDVI
	RI	0.577**	(659,661)			RI	0.634**	(687,744)	
	NDVI	0.579**	(686,687)			NDVI	0.633**	(720,753)	
	SAVI	0.669**	(682,732)			SAVI	0.741**	(728,738)	
	TVI	0.656**	(710,720)			TVI	0.755**	(687,754)	
	mSR	0.578**	(761,762)			mSR	0.581**	(718,724)	
	mNDI	0.58**	(661,682)			mNDI	0.596**	(690,768)	
0.5	DI	0.722**	(753,754)	DI、SAVI、TVI、mNDI、NDVI	2	DI	0.738**	(712,738)	DI、SAVI、TVI、mSR、mNDI
	RI	0.604**	(686,687)			RI	0.582**	(718,728)	
	NDVI	0.605**	(686,687)			NDVI	0.604**	(718,750)	
	SAVI	0.729**	(753,754)			SAVI	0.739**	(712,738)	
	TVI	0.733**	(700,720)			TVI	0.730**	(712,738)	
	mSR	0.603**	(768,771)			mSR	0.608**	(718,724)	
	mNDI	0.606**	(671,690)			mNDI	0.606**	(726,733)	
1	DI	0.733**	(736,738)	DI、SAVI、TVI、mNDI、NDVI					
	RI	0.599**	(761,785)						
	NDVI	0.608**	(681,687)						
	SAVI	0.733**	(736,738)						
	TVI	0.762**	(684,719)						
	mSR	0.598**	(686,687)						
	mNDI	0.624**	(750,751)						

2.3 大豆 LAI 预测模型构建与比较

以提取出的各阶最优光谱指数组合作为自变量,以大豆 LAI 作为响应变量,分别采用 SVM、RF、GA－BP 构建大豆开花结荚期 LAI 估算模型,从 R^2、RMSE、MRE 3 方面综合评定模型精度,不同建模方法对于大豆叶面积的预测结果如表 4、图 7 所示。

表 4 模型预测精度评价

Tab. 4 Comparison of model prediction accuracy evaluation under different differential orders

微分阶数	评价指标	SVM		RF		GA－BP	
		训练集	验证集	训练集	验证集	训练集	验证集
0	R^2	0.538**	0.503**	0.681**	0.636**	0.603**	0.523**
	RMSE/($cm^2 \cdot cm^{-2}$)	0.679	0.917	0.560	0.669	0.619	0.725
	NRMSE/%	22.004	29.698	18.13	21.656	20.019	23.476
	MRE/%	17.540	24.194	17.705	16.844	17.581	19.043
0.5	R^2	0.608**	0.559**	0.737**	0.684**	0.661**	0.603**
	RMSE/($cm^2 \cdot cm^{-2}$)	0.603	0.658	0.546	0.498	0.583	0.580
	NRMSE/%	19.523	21.311	17.678	16.117	18.867	18.765
	MRE/%	17.042	18.062	17.670	15.571	16.103	17.390
1	R^2	0.704**	0.661**	0.807**	0.758**	0.778**	0.684**
	RMSE/($cm^2 \cdot cm^{-2}$)	0.530	0.586	0.425	0.478	0.474	0.499
	NRMSE/%	17.138	18.957	13.748	15.456	15.332	16.160
	MRE/%	14.310	15.630	13.423	12.249	13.233	13.030
1.5	R^2	0.830**	0.776**	0.890**	0.880**	0.846**	0.813**
	RMSE/($cm^2 \cdot cm^{-2}$)	0.427	0.412	0.348	0.320	0.383	0.404
	NRMSE/%	13.833	13.324	11.278	10.354	12.379	13.074
	MRE/%	12.270	12.970	9.795	9.572	11.644	12.570
2	R^2	0.781**	0.740**	0.835**	0.812**	0.791**	0.765**
	RMSE/($cm^2 \cdot cm^{-2}$)	0.471	0.462	0.436	0.402	0.463	0.434
	NRMSE/%	15.228	14.957	14.122	13.001	14.985	14.031
	MRE/%	13.540	15.477	12.838	10.499	13.270	11.534

结果表明:不同阶微分变换处理下大豆 LAI 估算模型 R^2 从大到小依次为 1.5 阶、2 阶、1 阶、0.5 阶、0 阶;RMSE、NRMSE 与 MRE 从小到大均依次为:1.5 阶、2 阶、1 阶、0.5 阶、0 阶。1.5 阶微分光谱指数构建的 SVM、RF、GA－BP 大豆 LAI 预测模型的验证集 R^2 分别为:0.776、0.880、0.846,均高于 0.515,达到极显著相关水平,具有良好的线性拟合效果;NRMSE 介于 10% ~20% 之间,3 种模型的预测值与实测值之间的一致性呈较好水平。同阶微分变换处理下,3 种建模方法构建的大豆 LAI 估算模型的建模集与验证集精度从大到小依次为 RF、GA－BP、SVM。各阶微分处理下,基于 RF 构建的大豆 LAI 预测模型验证集 R^2 较 SVM 与 GA－BP 提高 0.047 ~0.133;NRMSE 与 MRE 分别降低 0.704 ~8.042 个百分点与 0.781 ~7.35 个百分点。综上所述,1.5 阶微分处理与 RF 方法分别为本研究中的最优微分阶数与最优模型构建方法,由此构建的最优大豆 LAI 估算模型建模集与验证集的 R^2 为 0.890 与 0.880,RMSE 分别为 0.348 cm^2/cm^2 与 0.320 cm^2/cm^2,NRMSE 分别为 11.278% 与 10.354%,MRE 分别为 9.795% 与 9.572%。

3 讨论

目前,在利用高光谱反射率数据进行 LAI 反演模型构建的研究中发现直接运用原始高光谱反射率对于作物 LAI 进行反演模型构建得到的模型精度往往较差[36]。引入微分变换处理,可以削弱光谱反射率背景噪声,突出高光谱特征信息,增强高光谱反射率与作物 LAI 间的相关性进而促进反演模型精度的提升[37-38]。本研究对高光谱反射率数据进行 0 ~2 阶分数阶微分处理(步长 0.5)构建大豆 LAI 反演模型,随着微分阶数的提高,光谱指数与大豆 LAI 的相关性与模型精度均呈现出先升后降的趋势,1.5 阶微分下最优光谱指数与大豆 LAI 相关性及其构建的预测模型精度均高于 1 阶与 2 阶整数微分。这是因为分数阶微分是高光谱反射率整数阶微分变换的拓展与延伸,可以提取整数阶微分无法表征的渐变性信息[39]。但是随着微分阶数提高,背景噪声被逐渐削弱,高频噪声会被逐渐放大,也减少了反射率数据中的潜在敏感信息,导致了光谱信息信噪比的降低,继而影响模型精度[40]。本研究发现在全波段范围内筛选波段构建的最优光谱指数包含了更多与大豆 LAI 相关的有效信息,且构建的 25 个 0 ~2 阶最优

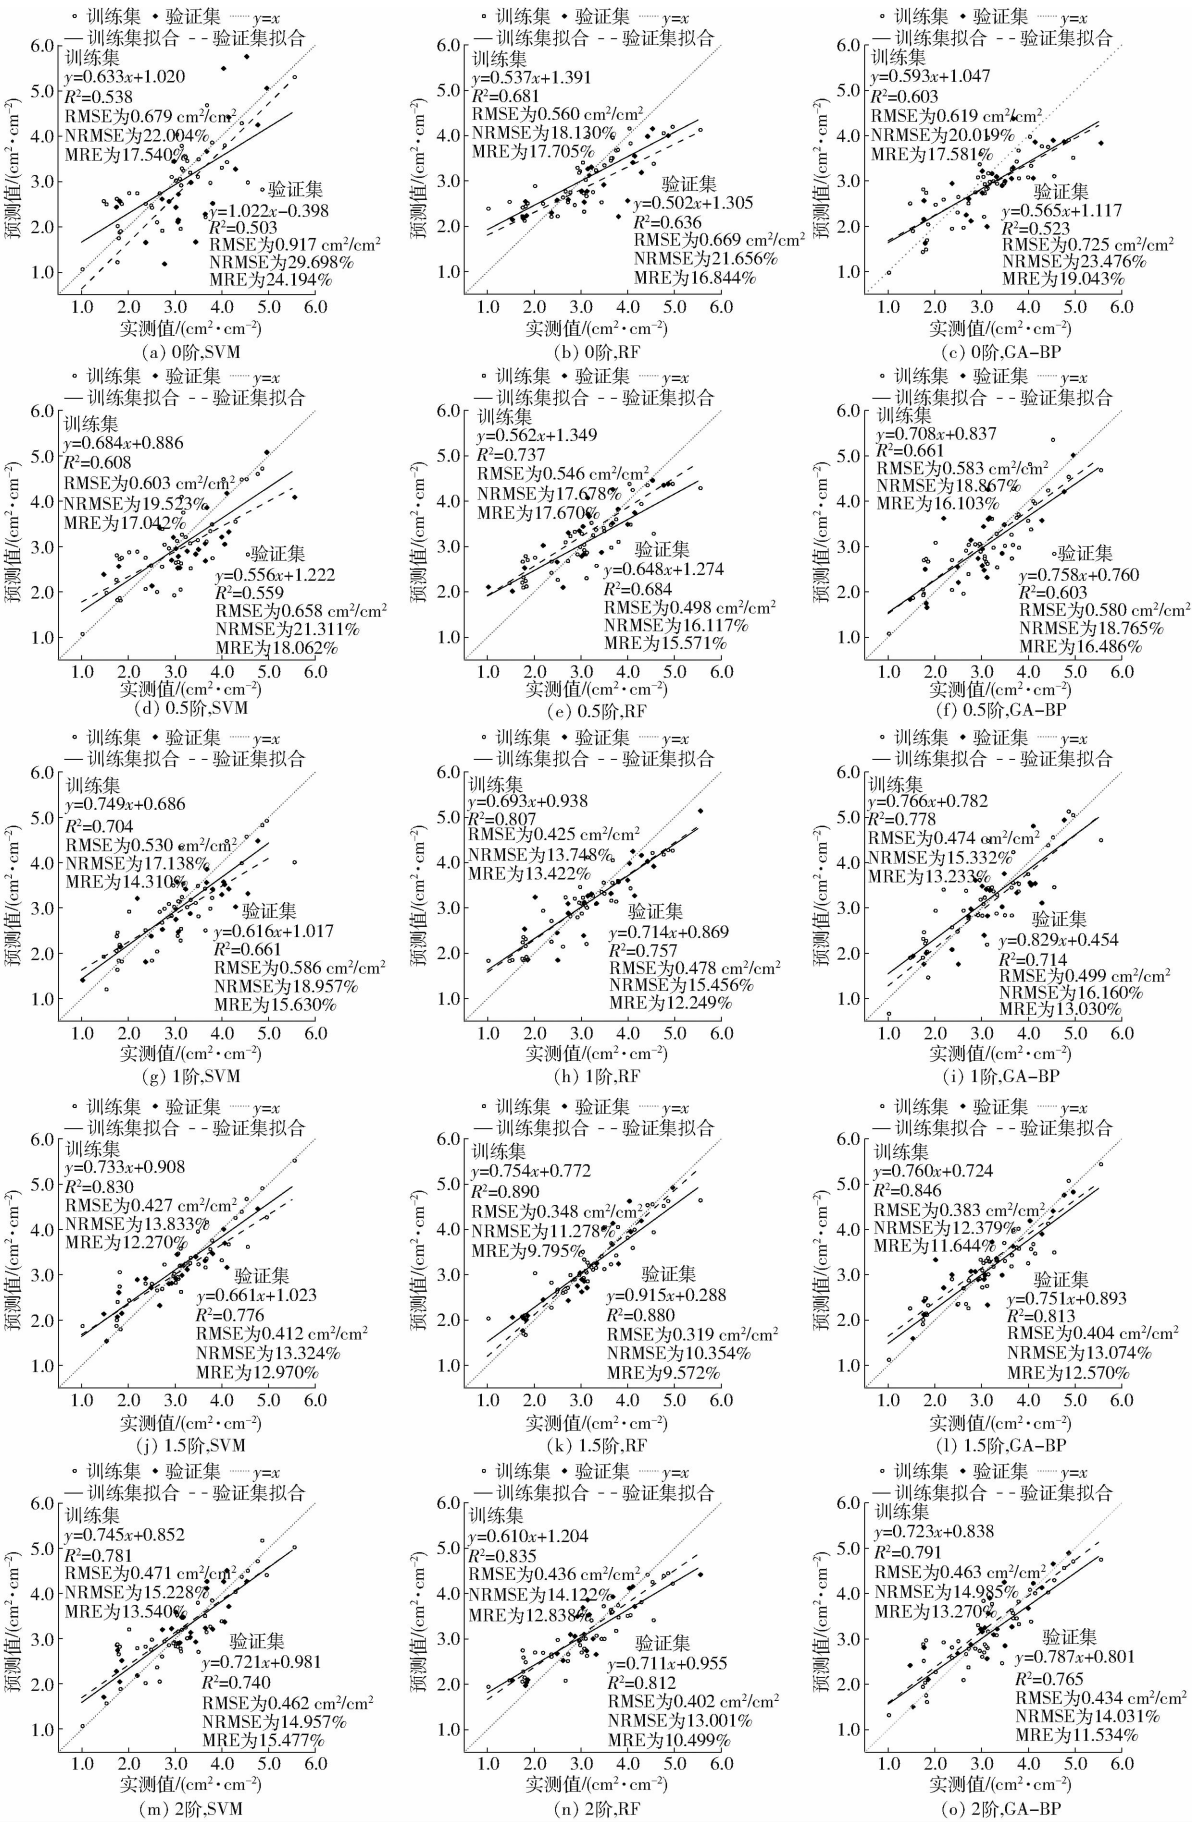

图 7　模型评价结果

Fig. 7　Model comparison results

光谱指数中的 23 个指数所对应的波段分布在红边或近红外波段。叶绿素对红光波段的强吸收和近红外波段在叶片内部发生的强反射使得红边波段成为绿色植物反射率增长最快速也是最能反映植物生长生理特征的重要指示波段,80% 以上的植物理化参数都可以从红边波段所包含的光谱信息中找到映射[41-42]。分数阶微分处理在过滤背景噪声的同时,也保留了红边波段对于植物理化参数的描述能力,因此本研究中各阶微分处理下筛选出的与大豆 LAI 呈极显著相关关系的波段组合多分布于 680 ~ 760 nm 范围内,与前人研究结果相符[43]。

本研究以选出的各阶最优光谱指数组合作为输入数据,选用 SVM、RF、GA - BP 共 3 种机器学习方法进行 LAI 预测模型的构建。3 种方法中,基于 RF 方法构建的 LAI 预测模型精度最高,说明 RF 提取光谱反射率数据中 LAI 相关信息的能力更强,这是因为 RF 算法具有较强的抗干扰与抗过拟合能力,对背景噪声与异常值的容忍性也更高,更适合解决一些非线性问题[44],陈晓凯等[45]对冬小麦 LAI 进行反演时也得到了相同的结果。BP 神经网络是一种按误差逆传播算法训练的监督式学习方法,也是当前应用最广泛的非线性多层前馈网络模型之一,但神经网络模型精度也因容易陷入局部极值且收敛速度较慢的缺点[46]受到了限制。遗传算法可对 BP 人工神经网络的初始权值和阈值进行优化,提高网络的收敛速度与识别精度[47]。本研究中 GA - BP 模型精度低于 RF,可能是因为样本相对较少但模型训练次数较高,导致了模型精度与泛化能力的降低[48]。与 RF 和 GA - BP 相比,SVM 模型对于 LAI 的预测效果较差,推测是因为 SVM 抗干扰性较弱且受到核函数与惩罚因子等参数选择的限制[49]。

当前,利用高光谱数据对作物的 LAI、生物量、氮素、叶绿素的模型研究取得了很好的效果,但常用的地面高光谱数据一般只能在地面进行获取,受限制条件较多。本研究结果表明以 1.5 阶最优光谱指数组合作为输入变量,采用 RF 构建 LAI 预测模型可以得出最佳的拟合精度,今后需要通过不同地区、不同尺度和不同品种类型的试验对模型进行检验和改进,实现模型估测精确性和普适性的有效统一,为使用多光谱和无人机高光谱等多源遥感手段预测多生育期大豆 LAI 与进一步探索高光谱反射率分数阶微分变换提供参考。

4 结论

(1)与原始高光谱反射率数据相比,分数阶微分变换后提取出的各阶最优光谱指数与大豆 LAI 的相关性得到显著提高,1.5 阶处理下各光谱指数与大豆 LAI 相关系数的平均值较原始光谱指数提高 0.053,其中 TVI(687 nm,754 nm)表现出最高的相关性,相关系数为 0.755。

(2)当建模方法相同,输入变量不同时,大豆 LAI 预测模型的精度从大到小依次为:1.5 阶、2 阶、1 阶、0.5 阶、原始阶位;当输入变量相同,建模方法变化时,大豆 LAI 预测模型的精度从大到小依次为:RF、GA - BP、SVM。综合比较模型的评价指标可知 1.5 阶微分与 RF 方法分别为本研究中的最优微分阶数与最优模型构建方法,由此构建的最优大豆 LAI 估算模型建模集与验证集的 R^2 分别为 0.890 与 0.880,RMSE 分别为 0.348 cm^2/cm^2 与 0.320 cm^2/cm^2,NRMSE 分别为 11.278% 与 10.354%,MRE 分别为 9.795% 与 9.572%。

参 考 文 献

[1] 张彩霞,付桢. 国际背景下中国大豆的生产困境分析与对策[J]. 河北经贸大学学报(综合版),2020,20(4):73 - 78.
ZHANG Caixia, FU Zhen. Analysis and countermeasure of production dilemma of Chinese soybean under the international background [J]. Journal of Hebei University of Economics and Business(Comprehensive Edition), 2020,20(4): 73 - 78. (in Chinese)

[2] 王乐政,华方静,曹鹏鹏,等. 不同播期夏大豆的产量、光合特性和气象因子效应研究[J]. 中国油料作物学报,2019,41(5):750 - 757.
WANG Lezheng, HUA Fangjing, CAO Pengpeng, et al. Effect of sowing date and climatic factor on yield and photosynthetic characteristics summer soybean[J]. Chinese Journal of Oil Crop Sciences,2019,41(5):750 - 757. (in Chinese)

[3] 赵虎,裴志远,马尚杰,等. 利用 HJ - 1 - A/B CCD2 数据反演冬小麦叶面积指数[J]. 农业工程学报,2012,28(10):172 - 176.
ZHAO Hu, PEI Zhiyuan, MA Shangjie, et al. Retrieving leaf area index of winter wheat using HJ - 1 - A/B CCD2 data[J]. Transactions of the CSAE, 2012,28(10):172 - 176. (in Chinese)

[4] VERRELST T, CAMPS-VALLS G, MUÑOZ-MARI J, et al. Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties—a review[J]. ISPRS Journal of Photogrammetry and Remote Sensing,2015,108:273 - 290.

[5] ZHENG G, MOSKAL L M. Retrieving leaf area index (LAI) using remote sensing: theories, methods and sensors[J]. Sensors, 2009,9(4):2719 - 2745.

[6] 易秋香. 基于 Sentinel - 2 多光谱数据的棉花叶面积指数估算[J]. 农业工程学报,2019,35(16):189 - 197.
YI Qiuxiang. Remote estimation of cotton LAI using Sentinel - 2 multispectral data[J]. Transactions of the CSAE, 2019, 35(16):189 - 197. (in Chinese)

[7] CHEN J M, CIHLAR J. Retrieving leaf area index of boreal conifer forests using Landsat TM images[J]. Remote Sensing of

Environment,1996,55(2):153 – 162.
[8] CHEN K, LI C, TANG R N. Estimation of the nitrogen concentration of rubber tree using fractional calculus augmented NIR spectra[J]. Industrial Crops and Products,2017,108:831 – 839.
[9] 赵春江. 农业遥感研究与应用进展[J]. 农业机械学报,2014,45(12):277 – 293.
ZHAO Chunjiang. Advances of research and application in remote sensing for agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014,45(12):277 – 293. (in Chinese)
[10] 刘潭,许童羽,于丰华,等. 基于 PROSAIL 模型偏差补偿的水稻叶绿素含量遥感估测[J]. 农业机械学报,2020,51(5):156 – 164.
LIU Tan,XU Tongyu,YU Fenghua,et al. Remote sensing estimation of rice chlorophyll content based on PROSAIL model deviation compensation[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(5):156 – 164. (in Chinese)
[11] 李娟,陈超,王昭. 基于不同变换形式的干旱区土壤盐分高光谱特征反演[J]. 水土保持研究,2018,25(1):197 – 201.
LI Juan, CHEN Chao, WANG Zhao. Inversion of high spectral characteristics of soil salt in arid area based on different transform forms[J]. Research of Soil and Water Conservation,2018,25(1):197 – 201. (in Chinese)
[12] LEYDEN K, GOODWINE B. Fractional-order system identification for health monitoring[J]. Nonlinear Dynamics, 2018, 92(3):1317 – 1334.
[13] SHIRI B, BALEANU D. System of fractional differential algebraic equations with applications[J]. Chaos, Solitons and Fractals,2019,120:203 – 212.
[14] 田安红,赵俊三,张顺吉,等. 基于分数阶微分的盐渍土电导率高光谱估算研究[J]. 中国生态农业学报(中英文),2020,28(4):599 – 607.
TIAN Anhong,ZHAO Junsan,ZHANG Shunji,et al. Hyperspectral estimation of saline soil electrical conductivity based on fractional derivative[J]. Chinese Journal of Eco-Agriculture,2020,28(4):599 – 607. (in Chinese)
[15] 李武耀,买买提·沙吾提,买合木提·巴拉提. 基于分数阶微分的土壤有机质含量高光谱反演研究[J]. 激光与光电子学进展,2023,60(7):394 – 401.
LI Wuyao,MAIMAITI·Shawuti,MAIHEMUTI·Balati. Hyperspectral inversion of soil organic matter content based on fractional differential[J]. Laser & Optoelectronics Progress,2023,60(7):394 – 401. (in Chinese)
[16] HONG Y. Application of fractional-order derivative in the quantitative estimation of soil organic matter content through visible and near-infrared spectroscopy[J]. Geoderma, 2019,337: 758 – 769.
[17] CHEN J, GU S, SHEN M, et al. Estimating aboveground biomass of grassland having a high canopy cover: an exploratory analysis of in situ hyperspectral data[J]. International Journal of Remote Sensing,2009,30(24):6497 – 6517.
[18] 安海波,李斐,赵萌莉,等. 基于优化光谱指数的牧草生物量估算[J]. 光谱学与光谱分析,2015,35(11):3155 – 3160.
AN Haibo, LI Fei, ZHAO Mengli,et al. Optimized soectral indices based estimation of forage grass biomass[J]. Spectroscopy and Spectral Analysis, 2015,35(11):3155 – 3160. (in Chinese)
[19] 张婷婷,向莹莹,杨丽明,等. 高光谱技术无损检测单粒小麦种子生活力的特征波段筛选方法研究[J]. 光谱学与光谱分析,2019,39(5):1556 – 1562.
ZHANG Tingting, XIANG Yingying, YANG Liming,et al. Wavelength variable selection methods for non-destructive detection of the viability of single wheat kernel based on hyperspectral images [J]. Spectroscopy and Spectral Analysis, 2019,39(5):1556 – 1562. (in Chinese)
[20] FAVA F, COLOMBO R, BOCCHI S, et al. Identification of hyperspectral vegetation indices for Mediterranean pasture characterization[J]. International Journal of Applied Earth Observation and Geoinformation,2009,11(4):233 – 243.
[21] 陈红艳,赵庚星,陈敬春,等. 基于改进植被指数的黄河口区盐渍土盐分遥感反演[J]. 农业工程学报,2015,31(5):107 – 114.
CHEN Hongyan, ZHAO Gengxing, CHEN Jingchun,et al. Remote sensing inversion of saline soil salinity based on modified vegetation index in estuary area of Yellow River[J]. Transactions of the CSAE, 2015, 31(5): 107 – 114. (in Chinese)
[22] 邵丽冰,陈奕云,徐璐,等. 基于分数阶微分的土壤含水量高光谱响应特征与估测模型构建[J]. 测绘地理信息,2022,47(增刊 1):131 – 136.
SHAO Libing, CHEN Yiyun, XU Lu, et al. Analysis on soil moisture content hyperspectral response and construction of estimation model based on fractional-order derivative[J]. Journal of Geomatics,2022,47(Supp. 1):131 – 136. (in Chinese)
[23] TANG Z J, GUO J J, XIANG Y Z,et al. Estimation of leaf area index and above-ground biomass of winter wheat based on optimal spectral index[J]. Agronomy,2022,12(7):1729 – 1746.
[24] SINHAL A,VERMA B. A distribution based approach of outlier removal for software effort data[J]. International Journal of Computer Applications,2013,74(20):24 – 28.
[25] 陈睿华,王怡婧,张俊华,等. 基于分数阶微分光谱指数的银川平原土壤含盐量反演[J/OL]. 生态学杂志,https://kns.cnki.net/kcms/detail/21.1148.Q.20270922.1142.010.html.
[26] 刘爽,于海业,张郡赫,等. 基于最优光谱指数的大豆叶片叶绿素含量反演模型研究[J]. 光谱学与光谱分析,2021,41(6):1912 – 1919.
LIU Shuang, YU Haiye, ZHANG Junhe, et al. Study on inversion model of chlorophyll content in soybean leaf based on optimal spectral indices[J]. Spectroscopy and Spectral Analysis, 2021,41(6):1912 – 1919. (in Chinese)
[27] 林卉,梁亮,张连蓬,等. 基于支持向量机回归算法的小麦叶面积指数高光谱遥感反演[J]. 农业工程学报,2013,29(11):139 – 146.
LIN Hui, LIANG Liang, ZHANG Lianpeng, et al. Wheat leaf area index inversion with hyperspectral remote sensing based on support vector regression algorithm[J]. Transactions of the CSAE, 2013, 29(11): 139 – 146. (in Chinese)
[28] VLADIMIR N. The nature of statistical learning theory[M]. New York: Springer,2000.
[29] 方匡南,吴见彬,朱建平,等. 随机森林方法研究综述[J]. 统计与信息论坛,2011,26(3):32 – 38.
FANG Kuangnan,WU Jianbin,ZHU Jianping,et al. A review of technologies on random forests[J]. Journal of Statistics and Information,2011,26(3):32 – 38. (in Chinese)

[30] KYOKO O. Machine learning [M]. Tritech Digital Media,2018.
[31] 张银,周孟然. 人工神经网络 BP 算法在近红外光谱分析中的应用[J]. 红外,2006(11):1 - 4.
ZHANG Yin, ZHOU Mengran. Application of artificial neural network BP algorithm in near infrared spectroscopy [J]. Infrared, 2006(11):1 - 4. (in Chinese)
[32] 杨练兵,郑宏伟,罗格平,等. 基于遗传算法优化 BP 神经网络的土壤盐渍化反演[J]. 地理与地理信息科学,2021,37(2):12 - 21,37.
YANG Lianbing, ZHENG Hongwei, LUO Geping, et al. Retrieval of soil salinity content based on BP neural network optimized by genetic algorithm[J]. Geography and Geo-Information Science, 2021,37(2):12 - 21,37. (in Chinese)
[33] 施端阳,林强,胡冰,等. 遗传算法优化神经网络的雷达杂波抑制方法[J]. 现代防御技术,2021,49(6):80 - 89.
SHI Duanyang,LIN Qiang,HU Bing,et al. Radar clutter suppression method based on neural network optimized by genetic algorithm[J]. Modern Defence Technology, 2021,49(6):80 - 89. (in Chinese)
[34] 陈俊英,王新涛,张智韬,等. 基于无人机-卫星遥感升尺度的土壤盐渍化监测方法[J]. 农业机械学报,2019,50(12):161 - 169.
CHEN Junying,WANG Xintao,ZHANG Zhitao,et al. Soil salinization monitoring method based on UAV - satellite remote sensing scale-up[J]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(12):161 - 169. (in Chinese)
[35] 陶惠林,徐良骥,冯海宽,等. 基于无人机数码影像的冬小麦株高和生物量估算[J]. 农业工程学报,2019,35(19):107 - 116.
TAO Huilin, XU Liangji, FENG Haikuan, et al. Estimation of plant height and biomass of winter wheat based on UAV digital image[J]. Transactions of the CSAE,2019,35(19):107 - 116. (in Chinese)
[36] LIANG L,DI L P,HUANG T, et al. Estimation of leaf nitrogen content in wheat using new hyperspectral indices and a random forest regression algorithm[J]. Remote Sensing,2018,10(12):1 - 16.
[37] WANG Z,ZHANG X L,ZHANG F,et al. Estimation of soil salt content using machine learning techniques based on remote-sensing fractional derivatives, a case study in the Ebinur Lake Wetland National Nature Reserve, Northwest China [J]. Ecological Indicators,2020,119:106869.
[38] HONG Y S, GUO L, CHEN S C, et al. Exploring the potential of airborne hyperspectral image for estimating topsoil organic carbon: effects of fractional-order derivative and optimal band combination algorithm[J]. Geoderma,2020,365:114228.
[39] 张俊华,贾萍萍,孙媛,等. 基于高光谱特征的盐渍化土壤不同土层盐分离子含量预测[J]. 农业工程学报,2019,35(12):106 - 115.
ZHANG Junhua, JIA Pingping, SUN Yuan, et al. Prediction of salinity ion content in different soil layers based on hyperspectral data[J]. Transactions of the CSAE, 2019, 35(12): 106 - 115. (in Chinese)
[40] 竞霞,张腾,邹琴,等. 基于分数阶微分光谱指数的小麦条锈病遥感监测模型构建[J]. 农业工程学报,2021,37(17):142 - 151.
JING Xia, ZHANG Teng, ZOU Qin, et al. Construction of remote sensing monitoring model of wheat stripe rust based on fractional-order differential spectral index[J]. Transactions of the CSAE, 2021, 37(17): 142 - 151. (in Chinese)
[41] 姚付启,张振华,杨润亚,等. 基于红边参数的植被叶绿素含量高光谱估算模型[J]. 农业工程学报,2009,25(增刊 2):123 - 129.
YAO Fuqi, ZHANG Zhenhua, YANG Runya, et al. Hyperspectral models for estimating vegetation chlorophyll content based on rededge parameter[J]. Transactions of the CSAE, 2009,25(Supp. 2):123 - 129. (in Chinese)
[42] TANAKA S Y, KAWAMURA K, MAKI M, et al. Spectral index for quantifying leaf area index of winter wheat by field hyperspectral measurements: a case study in Gifu Prefecture, Central Japan[J]. Remote Sensing,2015,7(5):5329 - 5346.
[43] 张智韬,台翔,杨宁,等. 不同植被覆盖度下无人机多光谱遥感土壤含盐量反演[J]. 农业机械学报,2022,53(8):220 - 230.
ZHANG Zhitao,TAI Xiang, YANG Ning, et al. UAV multispectral remote sensing soil salinity inversion based on different fractional vegetation coverages[J]. Transactions of the Chinese Society for Agricultural Machinery,2022,53(8):220 - 230. (in Chinese)
[44] FU Z P, YANG J J, GAO Y, et al. Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle[J]. Remote Sensing,2020,12(3):508 - 527.
[45] 陈晓凯,李粉玲,王玉娜,等. 无人机高光谱遥感估算冬小麦叶面积指数[J]. 农业工程学报,2020,36(22):40 - 49.
CHEN Xiaokai, LI Fenling, WANG Yu'na, et al. Estimation of winter wheat leaf area index based on UAV hyperspectral remote sensing[J]. Transactions of the CSAE, 2020, 36(22): 40 - 49. (in Chinese)
[46] 崔日鲜,刘亚东,付金东. 基于可见光光谱和 BP 人工神经网络的冬小麦生物量估算研究[J]. 光谱学与光谱分析,2015,35(9):2596 - 2601.
CUI Rixian, LIU Yadong, FU Jindong. Estimation of winter wheat biomass using visible spectral and BP based artificial neural networks[J]. Spectroscopy and Spectral Analysis, 2015,35(9):2596 - 2601. (in Chinese)
[47] 冯禹,王守光,崔宁博,等. 基于遗传算法优化神经网络的参考作物蒸散量预测模型[J]. 资源科学,2014,36(12):2624 - 2630.
FENG Yu, WANG Shouguang, CUI Ningbo, et al. Artificial neural networks optimized by genetic algorithms for modeling reference evapotranspiration in hilly area in central Sichuan [J]. Resources Science, 2014, 36(12): 2624 - 2630. (in Chinese)
[48] 周爱照,李罗鹏,仲冠宇,等. 基于遗传算法优化 BP 神经网络方法的旋转磨料射流开窗预测[J]. 科学技术与工程,2014,14(27):202 - 206.
ZHOU Aizhao, LI Luopeng, ZHONG Guanyu, et al. Prediction of casing window with swirling abrasive jet based on genetic algorithm optimization of BP artificial neural network[J]. Science Technology and Engineering, 2014,14(27):202 - 206. (in Chinese)
[49] SHEN H Z, JIANG K T, SUN W Q, et al. Irrigation decision method for winter wheat growth period in a supplementary irrigation area based on a support vector machine algorithm[J]. Computers and Electronics in Agriculture,2021,182:106032.