doi:10.6041/j.issn.1000-1298.2025.11.037

秋冬季未离田直立玉米秸秆高光谱可识别性研究

晁奥升[1,2]　朱庆伟[1]　邢恩光[2,3]　李存军[2,4]　刘　玉[2,4]　张津豪[2,3]

(1. 西安科技大学测绘科学与技术学院, 西安 710054; 2. 北京市农林科学院信息技术研究中心, 北京 100097;
3. 辽宁科技大学土木工程学院, 鞍山 114051; 4. 农业农村部农业遥感机理与定量遥感重点实验室, 北京 100097)

摘要: 探究秋冬季未离田直立玉米秸秆光谱特性和敏感波段是从农田相似地物中遥感准确识别秸秆的基础。本文采集了直立玉米秸秆及同时期相似地物共 9 类地物的高光谱数据,分析原始光谱及 3 种光谱变换的光谱曲线特征,并进行了秸秆高光谱可识别性研究。利用逐步判别分析法(SDA)和竞争性自适应加权采样法(CARS)筛选直立玉米秸秆的敏感光谱波段,最后利用随机森林(RF)、卷积神经网络(CNN)、长短期记忆递归神经网络(LSTM)和粒子群优化反向传播神经网络(PSO_BP)4 种分类器进行未离田直立玉米秸秆识别。结果表明,直立玉米秸秆在短波红外区域差异最明显,可见光区域次之;4 种光谱数据中,光谱变换的识别效果较好,平均识别精度大于 89%,其中一阶微分光谱变换的识别效果最高;2 种特征波段选择方法中,基于 SDA 的识别精度最高;4 种分类方法都能满足识别的精度要求,其中 PSO_BP 精度最高。实验结果表明,秋冬季未离田直立玉米秸秆有独特的高光谱特征和敏感波段,与相似地物具有可识别性,可为卫星和无人机的秋冬季未离田直立玉米秸秆遥感监测提供理论依据。

关键词: 直立玉米秸秆; 高光谱; 光谱变换; 敏感波段; 识别

中图分类号: S-3　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0387-10　　**OSID**:

Hyperspectral Identification of Upright Maize Straw in Autumn and Winter

CHAO Aosheng[1,2]　ZHU Qingwei[1]　XING Enguang[2,3]　LI Cunjun[2,4]　LIU Yu[2,4]　ZHANG Jinhao[2,3]

(1. *College of Geomatics*, *Xi'an University of Science and Technology*, *Xi'an* 710054, *China*
2. *Information Technology Research Center*, *Beijing Academy of Agriculture and Forestry Sciences*, *Beijing* 100097, *China*
3. *School of Civil Engineering*, *University of Science and Technology Liaoning*, *Anshan* 114051, *China*
4. *Key Laboratory of Agricultural Remote Sensing Mechanism and Quantitative Remote Sensing*, *Ministry of Agriculture and Rural Affairs*, *Beijing* 100097, *China*)

Abstract: Investigating the spectral characteristics and sensitive bands of the upright maize straw during this period forms the basis for accurately identifying straw among similar land cover types. Hyperspectral data for the upright maize straw and nine other types of land cover were collected during the same period. The spectral curve features of raw spectra and three mathematical transformations were analyzed, and their separability was evaluated. Utilizing stepwise discriminant analysis (SDA) and competitive adaptive reweighted sampling (CARS), sensitive spectral bands for standing the upright maize straw were identified. Subsequently, four classifiers—random forest (RF), convolutional neural network (CNN), long short-term memory recurrent neural network (LSTM), and particle swarm optimization back propagation neural network (PSO_BP)—were employed for identifying the upright maize straw left in the field. The results indicated that the upright maize straw exhibited the most pronounced differences in the shortwave infrared region, followed by the visible light region. Among the four spectral datasets, raw spectra showed lower recognition effectiveness, while transformed spectra achieved high accuracy, with an average recognition precision exceeding 89%, particularly for the first-order differential transformed spectral data. Regarding feature wavelength selection methods, SDA-based approaches demonstrated the highest recognition accuracy. All four classification methods met the accuracy requirements for identification, with PSO_BP achieving the highest precision. These experiments demonstrated the upright

收稿日期: 2024-07-29　修回日期: 2024-08-25

基金项目: 国家重点研发计划项目(2023YFD1501302)和北京市农林科学院科研平台建设课题(PT2024-26)

作者简介: 晁奥升(1999—),男,硕士生,主要从事农业定量遥感研究,E-mail: chaoas0225@163.com

通信作者: 李存军(1975—),男,研究员,博士,主要从事农业定量遥感与应用研究,E-mail: licj@nercita.org.cn

maize straw during autumn and winter exhibited unique spectral characteristics and sensitive bands, providing theoretical support for remote sensing monitoring by using satellites and unmanned aerial vehicles (UAVs).

Key words: upright maize straw; hyperspectral; spectral transformation; sensitive band; recognition

0 引言

我国拥有丰富的秸秆资源,据农业农村部 2021 年《全国农作物秸秆综合利用情况报告》,全国秸秆可收集资源量约为 7.34 亿吨,利用量约为 6.47 亿吨。玉米是中国第一大粮食作物,在东北一熟制地区或华北平原地下漏斗区的节水型作物种植带等地,玉米成熟后农田成为冬闲田。一部分玉米成熟后秸秆由农机粉碎直接还田,但也存在大量人工摘穗收获后玉米秸秆直立于田间。部分农民将玉米秸秆作为牛羊养殖的饲料,但很多农户采取田间焚烧、丢弃河道等手段处理,这不仅造成了秸秆资源的浪费,同时也污染了环境。我国 2014—2018 年田间秸秆焚烧火点共计 27 375 个,秸秆焚火点集中出现在 10—11 月和 2—4 月[1]。国家颁布相关政策,一方面倡导直立玉米秸秆收获综合利用[2],另一方面投入大量人力在秸秆焚烧的敏感区进行秸秆禁烧宣传和区域巡查。为指导养殖企业秸秆采收综合利用、避免秸秆焚烧污染环境,掌握秋冬季大区域未离田直立玉米秸秆的位置、分布和面积信息尤为重要,而如何快速低成本准确识别大面积直立玉米秸秆是首要解决的问题。

传统的秸秆监测依靠大量人员进行巡查,费时费力且效率低下[3],遥感技术的发展为解决这些问题提供了强有力的工具。卫星遥感监测大多基于多光谱遥感数据,因其覆盖范围宽、时效性强、处理速度快、获取成本低等优点[4],已成为农业资源调查的重要手段,初步用于大范围的秸秆分布监测中[5-7]。

在秋冬季节,与直立玉米秸秆相似的地物有干枯草、越冬期覆盖度较低的小麦、玉米秸秆残茬地和土壤等,这些地物表现为黄色或亮黄色、浅黄色,在多光谱影像,尤其是只包含可见光、近红外波段的影像上,与直立玉米秸秆存在混淆,影响提取精度。受限于光谱分辨率和波段数量,多光谱遥感技术在处理复杂地物和相似地物时,容易产生“同物异谱”或“同谱异物”的情况[8],往往造成误分和错分的情况。随着高光谱技术的发展,高光谱遥感可以获取高分辨率的光谱数据,产生更多的光谱细节[9],反映地物的光谱反射特征,被广泛应用于农业、林业等精细识别,如品种鉴定[10]、相似性地物识别[11-12]和病虫害检测[13]等。目前常用的高光谱卫星数据有珠海一号 OHS 高光谱卫星、高分五号、ISS DESIS 和 HySIS 卫星等,已被应用于大尺度的地物分类和监测,然而未离田直立玉米秸秆的敏感波段尚未明确且高光谱卫星识别鲜有报道。

基于地物光谱仪的不同地物地面实测高光谱数据可以快速、准确、无损和重复地获取研究区被测地物的光谱信息,能够更好地捕捉精细的地物特征,且没有大气效应的干扰,已成为许多专家学者研究不同地物光谱特性的重要手段。一些研究基于地面实测高光谱数据,采用一阶导数、连续统去除等光谱变换,通过放大原始光谱间的差异,观测到原始光谱数据中没有的细微差异,在针对特定地物识别场景中,能够在某些波段上增强特定特征,从而得到一个较好的分类识别精度[14]。然而,高光谱数据量大,波段间相关性强,存在信息冗余。在直立玉米秸秆识别应用中,为了得到敏感波段以及更好的识别效果,需要进行特征提取来解决信息冗余问题[15-20]。

然而,直立玉米秸秆与相似地物的光谱差异、直立玉米秸秆光谱特征及敏感波段等问题有待深入了解。本文获取秋冬季直立玉米秸秆在内的 9 类地物野外实测高光谱数据,对原始光谱进行 3 种光谱变换,然后利用 2 种特征提取方法获取敏感波段,最后使用 4 种分类器开展秋冬季未离田直立玉米秸秆高光谱可识别性研究。以期获得适合直立玉米秸秆识别的最佳识别光谱数据、敏感波段和最优特征获取方法,为秋冬季未离田直立玉米秸秆识别提供技术支撑。

1 研究区概况与数据采集

1.1 研究区概况

研究区位于北京市小汤山国家精准农业示范基地(40.10°N,116.26°E),海拔 39 m,属温带大陆性气候,主要作物为冬小麦和夏玉米,土壤为黏质土。冬季实验田主要有 9 类地物,如图 1 所示,分别为直立玉米秸秆、残茬地、干枯草、疏小麦、密小麦、残茬小麦地、裸土、碎石路和翻耕土。直立玉米秸秆为玉米籽粒收获后留在田间的较完整的植株,残茬地为玉米秸秆收割后残存根部的区域,密小麦为长势较强,覆盖度达到 30% ~45% 的小麦,疏小麦为覆盖率达到 15% ~30% 的小麦,残茬小麦地为农田中存

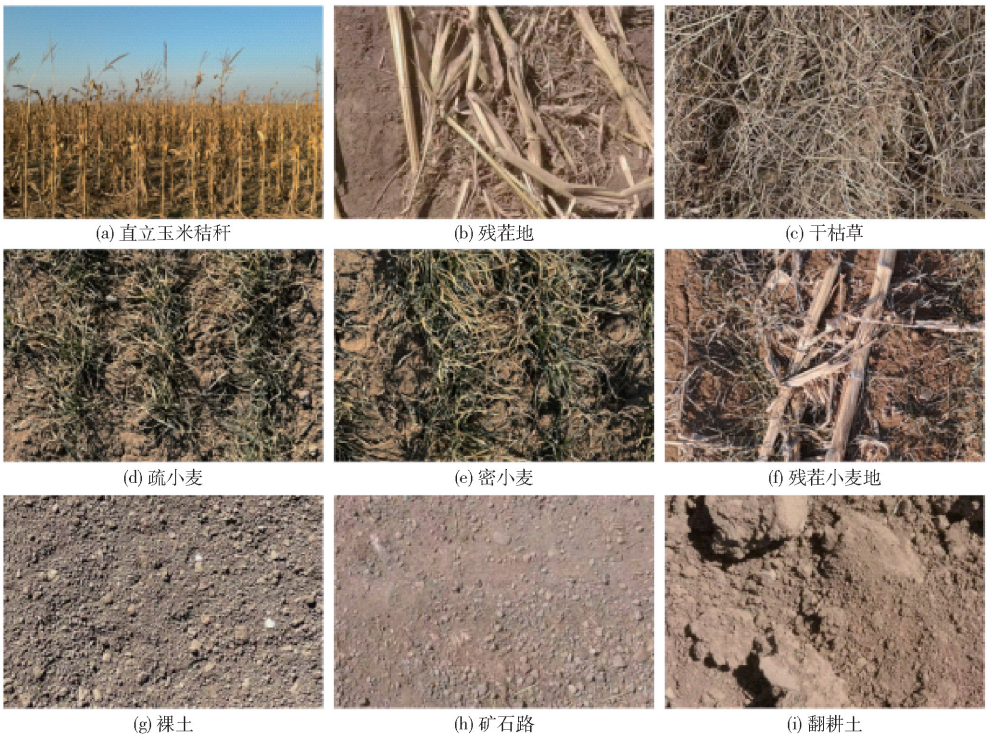


图 1　田间 9 类相似地物

Fig. 1　9 types of similar objects in field

在部分玉米残茬的小麦种植区，属于保护性耕作方式，干枯草为冬季干枯的低矮丛生杂草，裸土为冬季撂荒未耕作的土地，翻耕土为农机犁地作业后形成的翻耕土地，碎石路为铺设部分碎石的乡间土路。

这 9 类地物是研究区常见地物，远看为黄色或亮黄色、浅黄色，其他地物与直立玉米秸秆在可见近红外光谱波段光谱曲线存在交叉重叠现象，是典型的相似地物。

1.2　数据采集

本研究光谱测定使用 ASD 便携式野外光谱仪，波段为 350 ~ 2 500 nm，仪器视场角为 25°。采集时间为北京时间 10:30—14:00，采集时天空晴朗、干燥、湿度小、无风。每条光谱曲线连续采集 10 次取平均值作为本次采集的光谱曲线。每隔 15 min 或外界光照等变化较大时进行白板校正。

每类地物采集 30 个样本，每个样本采集 10 条光谱曲线，对获取的每个样本求均值作为该样本的光谱曲线。在测定地物光谱时，光谱仪探头垂直向下，在测定直立玉米秸秆光谱时，由于直立玉米秸秆较高，需要搭配梯子，采用光谱仪配套的加长光纤及探头，测定直立秸秆的冠层光谱。

2　研究方法

2.1　高光谱数据预处理

高光谱数据通过 ASD 光谱仪配套软件 ViewSpecPro 进行预处理。去掉受大气影响严重波段和水汽吸收波段，最终保留光谱波段为 352 ~ 1 349 nm、1 411 ~ 1 799 nm 和 1 921 ~ 2 300 nm。原始光谱数据中混杂噪声以及其他干扰因素，会对光谱数据的正常处理产生干扰，因此在光谱分析中经常对光谱数据进行各种变换，来减小该影响。本研究选取了经过平滑处理的原始光谱以及 3 种变换光谱，共计 4 种光谱曲线：移动平均平滑法（R）、一阶微分法（R'）、倒数的对数法（Log(1/R)）和连续统去除法（CR）。

移动平均平滑法对采集的直立玉米秸秆等光谱曲线进行去噪，以消除仪器自身内部带来的干扰[21]。具体做法是把光谱曲线上某点前后一段光谱的值求平均作为该点的值，计算公式为

$$R_i = \frac{1}{2j+1}(R_{i-j} + \cdots + R_i + \cdots + R_{i+j}) \quad (1)$$

式中　R_i——波长 i 的反射率　　j——正整数

一阶微分法[22]是常见且有效的高光谱数据处理方法。微分后的光谱能消除不同光谱数据间的系统误差、有效削弱大气背景噪声对直立玉米秸秆等地物光谱的影响，有效提取直立玉米秸秆等可识别地物的波长位置。一阶微分公式为

$$R'(\lambda_i) = \frac{R(\lambda_{i+1}) - R(\lambda_i)}{\Delta\lambda} \quad (2)$$

式中　$R'(\lambda_i)$——波长 i 和波长 $i+1$ 之间的一阶微分光谱

$R(\lambda_i)$——波长 i 对应的原始光谱反射率

$R(\lambda_{i+1})$——波长 $i+1$ 对应的原始光谱反射率

$\Delta\lambda$——波长 $i+1$ 和波长 i 之间的波长差值

倒数的对数法[23]作为高光谱数据处理的常用方法,其含义就是将实测光谱数据先经倒数处理再取对数得到被测物的光谱曲线。它的优点是相较于原始光谱,能够使直立玉米秸秆与其他地物光谱曲线间的细小差异得到进一步放大,便于进一步分析。计算公式为

$$A(\lambda_i) = \lg(1/R(\lambda_i)) \tag{3}$$

式中 $A(\lambda_i)$——波长 i 处倒数的对数值

连续统去除法又称包络线法[24]。在测量直立玉米秸秆、干枯草等地物时,会受到土壤背景的影响,使光谱曲线含有噪声,从而导致地物的某些光谱特征处细节弱化。使用连续统去除,可以去除土壤背景噪声,反映真实的地物光谱反射率变化,计算公式为

$$R_c(\lambda) = R_{cr}(\lambda) - R(\lambda) \tag{4}$$

式中 $R_c(\lambda)$、$R_{cr}(\lambda)$、$R(\lambda)$——去连续统去除后、连续统去除和光谱反射率

2.2 地物高光谱识别方法

2.2.1 敏感波段提取

高光谱数据包含了大量不同波段范围的光谱信号,其中一些波段在光谱响应上非常相似,具有冗余性。因此有必要通过特征变量的选取,筛选敏感波段,减少数据处理和分析的计算复杂性,提高目标地物的分类识别能力。

本研究使用 2 种特征变量选取方法,逐步判别分析法(Stepwise discriminant analysis,SDA)和竞争性自适应加权重采样法(Competitive adaptive reweighted sampling, CARS)。SDA 又称逐步回归方程,在判别分析中有许多变量,其通过建立一些测试规则,依次引入和消除变量,最终筛选出最优变量[25]。本研究中利用逐步判别分析对原始光谱数据和光谱变换后的光谱数据进行特征波段筛选,对获得的连续波段每 10 nm 求取平均值,得到压缩后的光谱数据作为分类器的输入数据。CARS 是采用蒙特卡洛采样以及偏最小二乘回归法的特征波段优选方法[26]。可以在高维数据中选择敏感波段,保持数据的区分性。本研究中,设置蒙特卡洛采样次数为 50,并通过 10 折交叉验证选择 RMSECV 最小的子集,从而寻找到最优解变量的集合。

2.2.2 分类方法

本文采用随机森林(Random forest,RF)、卷积神经网络(Convolutional neural networks,CNN)、长短期记忆递归神经网络(Long short term memory, LSTM)和粒子群优化反向传播神经网络(Particle swarm optimization backpropagation neural network, PSO-BP)4 种分类器进行实验。RF[27]是一个以决策树为基础分类器的集成学习(Ensemble learning)方法,通过组合多个决策树来改善预测性能,具有高度的鲁棒性、准确性和能够应对过拟合等优点。CNN[28]是机器学习领域用于深度监督学习的一种神经网络,由输入层、卷积层、池化层、全连接层和目标函数构成。LSTM[29]是一种特殊类型的递归神经网络(RNN),能够通过自我门控机制网络实现何时更新、遗忘和输出信息,从数据中学习有效的特征表示,提高识别的准确性。PSO-BP[30]是一种将粒子群优化算法与反向传播神经网络结合的网络,能够优化神经网络的权重和偏差,从而提高模型的性能。选择这些算法是基于其广泛的应用以及在处理复杂非线性关系、特征提取和泛化性能方面的能力。RF 在捕捉非线性模式方面表现出色,而 PSO-BP 则因其对复杂关系的建模能力而受到青睐。深度学习算法方面,选取 CNN 和 LSTM 对 9 种地物的主要特征进行分类,以更全面地评价直立秸秆及其相似地物的可分性。以上分类模型均采用 Matlab 构建。

2.3 分类精度评价

利用 SDA 和 CARS 对平滑去噪的光谱数据(R)、一阶微分光谱数据(R')、倒数的对数变换数据($\mathrm{Log}(1/R)$)和连续统去除数据(CR)分别进行敏感波段的筛选,共得到 8 个数据集。每类地物 30 个样本,每次按照比例 2∶1随机建立训练集和验证集,同时为检验结果的准确性,每个过程重复 3 次。

使用总体分类精度(OA)、F1 分数来评价相似地物的可分性和直立玉米秸秆识别的精度。OA 表示模型分类方法正确分类的样本数与总样本数之比,它可以表征整个分类器的识别性能,可以很好地反映模型的分类准确度和分类结果的整体误差。F1 分数是精准率和召回率的调和平均值,它综合考虑了模型的准确性和识别能力,F1 分数越高,说明模型的综合性能越好。

3 结果与分析

3.1 直立玉米秸秆及相似地物光谱分析

地物内部结构和成分变化导致地物间在光谱反射率方面存在差异。9 类地物产生的 4 条光谱曲线如图 2a 所示,可以得出:①直立秸秆、干枯草与其他地物光谱有明显差异,尤其是在短波红外 2 100 nm 附近波段,具有明显的吸收特性。②在可见光部分(波段 400~700 nm),直立秸秆的光谱曲线缓慢上升,冬小麦的光谱反射率为阶跃函数曲线,翻耕土、

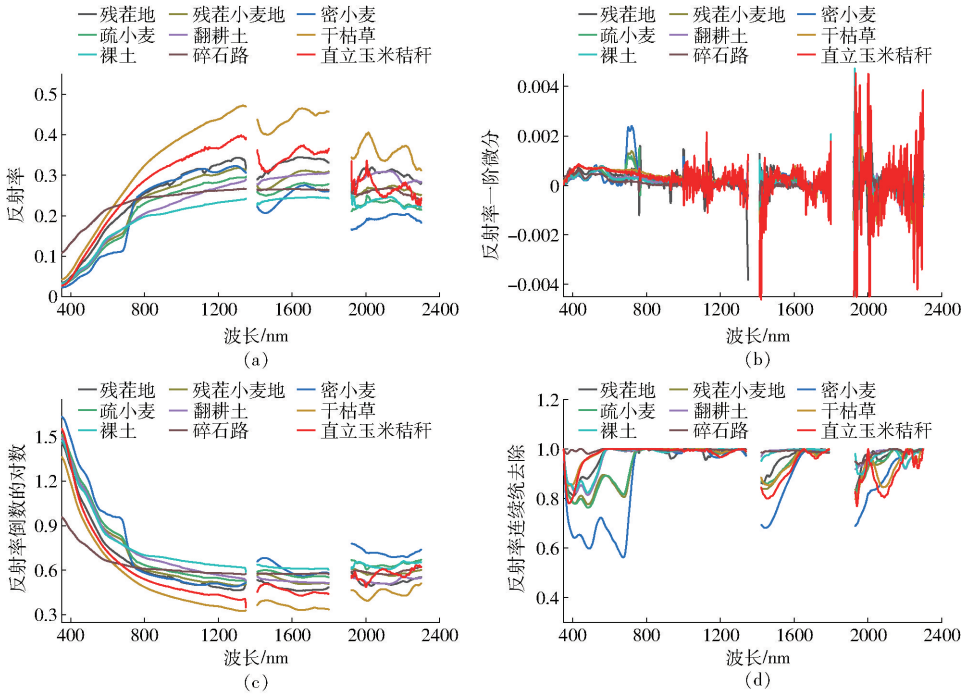


图 2　直立玉米秸秆及其相似地物原始光谱与变换光谱

Fig. 2　Original spectrum and transform spectrum of upright maize stalk and its similar objects

裸土等地物反射率也呈缓慢上升趋势，但反射率较低。③直立秸秆的反射率小于干枯草的反射率，大于秸秆残茬的反射率。图 2b 一阶微分曲线显示了 9 类地物的斜率变化和峰值信息，结果显示：①第 1 个较小的峰值出现在波段 480 ~ 550 nm 范围内，主要受小麦等绿色植被叶绿素含量及其光谱吸收特性的影响。②第 2 较大峰值出现在 680 ~ 750 nm 的红光波段，该波段是叶绿素的强吸收波段，直立秸秆在此与小麦地物表现出明显差异。③直立秸秆在短波红外波段（波段 1 400 ~ 2 300 nm）存在明显的峰值变化趋势，其他地物则表现不明显。使用倒数的对数放大地物间的增益，如图 2c 所示，在近红外区域（波段 750 ~ 1 100 nm）和短波红外区域（波段 1 400 ~ 2 300 nm）处直立玉米秸秆与其他地物光谱差异明显，有助于筛选提取敏感波段，提高研究区直立玉米秸秆识别的准确性。图 2d 为 9 种地物的连续统去除光谱曲线，所有地物被放在同一基准下进行比较。可以得出：①波段 400 ~ 600 nm 范围内，直立秸秆与其他地物波形区别显著，且数值明显高于其他地物。②在短波红外 2 100 nm 左右出现吸收峰使得干枯草与直立秸秆与其他地物表现出明显差异。③将直立秸秆与其他地物的差异缩小至可见光和短波红外 2 个范围，在对应的吸收谷区域，不同地物之前的差异被放大。

由此得出，倒数的对数以及原始光谱效果能够对直立秸秆提取起到一定辅助作用，但一阶微分曲线、连续统去除 2 种光谱变换取得的效果最好，不仅有效扩大了直立秸秆与其他地物的差异，而且把直立秸秆的敏感区间范围缩小至可见光波段 400 ~ 700 nm 与短波红外波段 2 000 ~ 2 200 nm。

在直接观测原始光谱反射率曲线的基础上，计算了直立玉米秸秆与其他地物的欧氏距离（图 3），欧氏距离越大，证明两者的可分性越强，反之，欧氏距离越小，两者的可分性越低。由图 3 可知，9 类地物中，干枯草同其它地物的欧氏距离均比较大，说明干枯草同其他地物间可分性最大，最易区分；其次直立玉米秸秆与其他地物光谱存在可分性，大小排序依次为：干枯草、碎石路、翻耕土、密小麦、裸土、残茬、疏小麦、残茬小麦。另外直立玉米秸秆与残茬地、残茬小麦地、密小麦和疏小麦之间欧氏距离较小，说明上述地物与直立玉米秸秆互为相似地物。

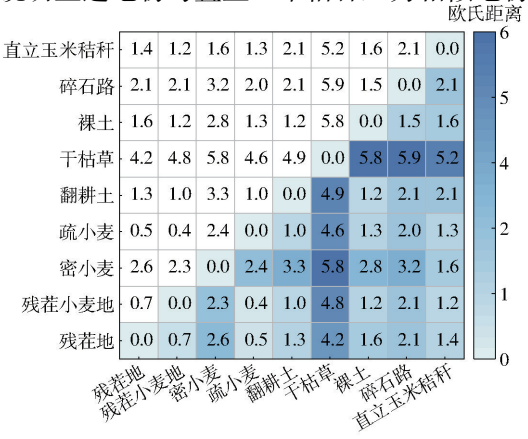


图 3　直立玉米秸秆及其相似地物间的欧氏距离

Fig. 3　Euclidean distance between upright maize straw and similar features

3.2 敏感波段提取

3.2.1 基于 SDA 的敏感波段提取

利用逐步判别分析对原始光谱数据和光谱变换后的光谱数据进行特征波段筛选,筛选的特征波段见表 1。压缩后的原始光谱的特征波段共有 17 个,可见光 3 个特征波段,近红外 3 个特征波段,短波红外 11 个特征波段;一阶微分光谱的特征波段共有 15 个,可见光 3 个特征波段,近红外 3 个特征波段,短波红外 9 个特征波段;倒数的对数光谱的特征波段共有12 个,可见光4个特征波段,近红外2个特征波段,短波红外 6 个特征波段;连续统去除光谱的特征波段共有 13 个,可见光 4 个特征波段,短波红外 9 个特征波段。由统计数据可知,敏感波段多分布于短波红外区域,可见光次之,近红外区域最少。

表 1 基于 SDA 的敏感波段筛选

Tab. 1 Feature band screening based on SDA

光谱变换	敏感波段/nm
R	352 ~ 407, 474 ~ 518, 651 ~ 695 929 ~ 945, 1 070 ~ 1 085, 1 108 ~ 1 148 1 307 ~ 1 317, 1 325 ~ 1 349, 1 411 ~ 1 442, 1 464 ~ 1 482, 1 723 ~ 1 732, 1 764 ~ 1 773, 1 777 ~ 1 799, 1 921 ~ 1 947, 1 994 ~ 2 015, 2 029 ~ 2 041, 2 193 ~ 2 209
R'	352 ~ 391, 536 ~ 571, 684 ~ 736 991 ~ 1 000, 1 105 ~ 1 118, 1 147 ~ 1 158 1 327 ~ 1 349, 1 411 ~ 1 446, 1 720 ~ 1 738, 1 783 ~ 1 799, 1 921 ~ 1 942, 1 944 ~ 1 959, 1 990 ~ 2 017, 2 179 ~ 2 191, 2 245 ~ 2 260
$\mathrm{Log}(1/R)$	352 ~ 431, 462 ~ 504, 536 ~ 584, 653 ~ 690 752 ~ 763, 1 111 ~ 1 144 1 330 ~ 1 349, 1 411 ~ 1 467, 1 768 ~ 1 799, 1 921 ~ 1 962, 1 992 ~ 2 018, 2 264 ~ 2 300
CR	352 ~ 421, 427 ~ 514, 542 ~ 607, 649 ~ 699 1 314 ~ 1 349, 1 411 ~ 1 444, 1 456 ~ 1 470, 1 721 ~ 1 729, 1 779 ~ 1 799, 1 921 ~ 1 955, 1 980 ~ 2 016, 2 195 ~ 2 210, 2 279 ~ 2 300

3.2.2 基于 CARS 的敏感波段提取

利用 CARS 对原始光谱数据和光谱变换后的光谱数据进行特征波段筛选,设置蒙特卡洛采样次数为 50,并通过 10 折交叉验证选择 RMSECV 最小的子集,寻找到最优解变量的集合。以直立玉米秸秆光谱数据为例,重复该过程 10 次,选出 RMSECV 值最小的子集,不同变换数据波段位置分布见图 4,可以看出直立秸秆的敏感波段多数分布在短波红外区域,尤其是在波段 2 000 ~ 2 200 nm 区间,对于原始光谱而言,在全波段都有分布,通过 3 种光谱变换之后,区域更加明显集中在短波红外区域,这是由于木质素和纤维素的影响,在波段 2 100 nm 处存在吸收。

3.3 直立玉米秸秆识别精度

针对获取的高光谱数据,将直立玉米秸秆及其相似地物经过不同光谱变换处理,利用 SDA 和 CARS 进行特征波段提取,秸秆识别精度如表 2 所示。经过光谱变换后,总体精度 OA 均大于 89%,秸秆 F1 分数大于 0.9,说明了高光谱数据在识别直立玉米秸秆及其相似性地物具有可分性。

3.3.1 不同波段选择方法识别精度比较

SDA 和 CARS 不同波段选择方法识别效果见图 5。可以看出,2 种特征波段选择方法中,SDA 中 4 种光谱数据的识别精度较为稳定,且 OA 高于 CARS,说明 SDA 的识别效果优于 CARS 的识别效果。CARS 筛选得到的是单个波段位置,表现的都

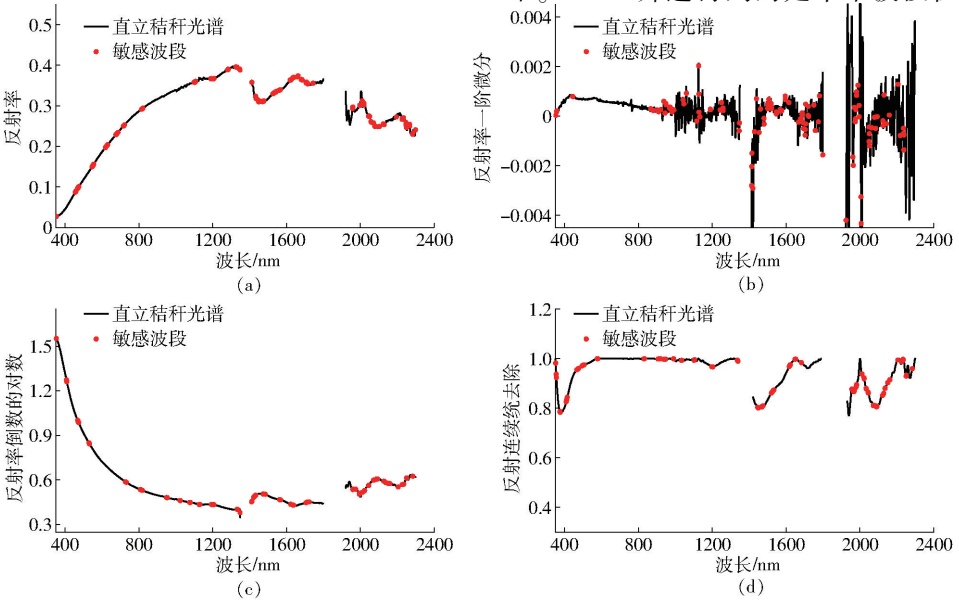


图 4 基于 CARS 的波段位置分布

Fig. 4 Band location distribution based on CARS

表 2　不同分类方案精度

Tab. 2　Accuracy of different classification schemes

波段选择	光谱变换	RF		CNN		LSTM		PSO_BP	
		OA/%	F1 分数	OA/%	F1 分数	OA/%	F1 分数	OA/%	F1 分数
SDA	R	93.57	0.94	89.29	0.91	91.43	0.97	97.86	0.97
	R'	98.57	0.96	95.00	1.00	93.57	0.97	95.71	0.94
	$\mathrm{Log}(1/R)$	95.71	0.98	97.86	1.00	97.86	1.00	98.57	1.00
	CR	98.57	1.00	97.86	1.00	98.57	1.00	99.29	1.00
CARS	R	93.57	0.94	90.00	0.94	90.71	0.92	95.71	0.86
	R'	99.29	1.00	97.86	1.00	99.23	0.93	96.43	0.97
	$\mathrm{Log}(1/R)$	92.14	1.00	90.00	0.96	91.43	1.00	97.86	1.00
	CR	97.86	0.93	92.86	0.95	88.57	1.00	95.00	1.00

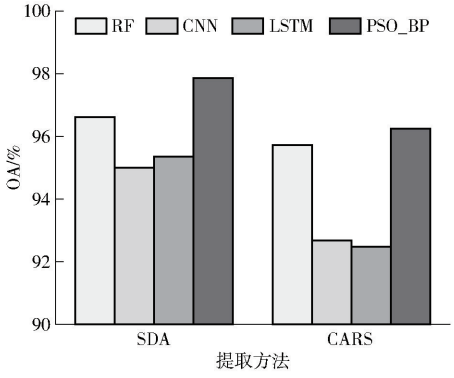


图 5　2 种特征波段提取方法分类精度比较

Fig. 5　Comparison of accuracy of two feature wavelength extraction methods

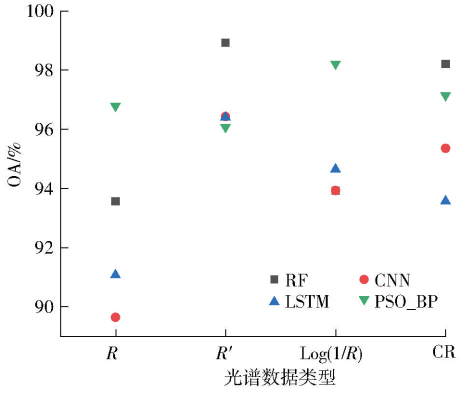


图 6　原始光谱及 3 种光谱变换分类精度比较

Fig. 6　Comparison of classification accuracy of original spectra and three mathematical transformations

是离散的特征，SDA 通过逐步判别分析筛选的特征波段是大于 10 nm 的连续波段，地物的光谱特征具有连续性，连续波段数据能够较好地反映这种连续性，更全面地提供特征信息。

3.3.2　4 种光谱数据分类精度比较

本文共选择 4 种光谱特征数据参与直立玉米秸秆识别，图 6 为不同光谱数据的识别精度，可以看出，光谱变换后的光谱数据识别精度要大于原始光谱数据识别精度，利用光谱变换对原始光谱进行处理后，增强了光谱数据的特性，放大了不同地物间的光谱细节变化，提高了不同地物间的可分离性。

本研究中 9 种地物原始光谱反射率的 4 种分类结果整体偏低，经过一阶微分、倒数的对数、连续统去除 3 种形式光谱变换后，分类结果均明显提高，其中一阶微分变换后的分类效果最好，分类精度均在 96% 以上。其他变换数据识别精度没有表现出明显的规律。这与文献[14]的研究结果类似，但更多的研究则表明这种规律不具有普遍性，识别对象、采集方式的不同，变换数据的适用性也不同。

3.3.3　4 种分类器精度比较

4 种分类器在直立玉米秸秆及其相似地物识别的适用性比较如图 7 所示。RF 和 PSO_BP 的识别效果优于 CNN 和 LSTM。进一步比较发现，RF 虽然

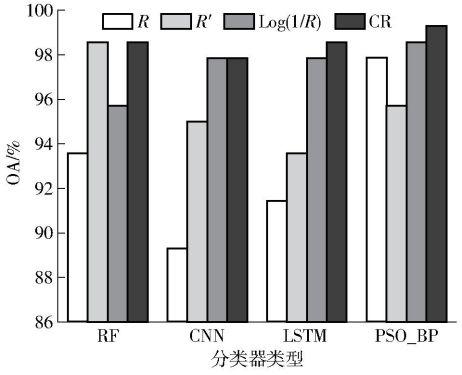


图 7　分类器精度比较

Fig. 7　Classifier accuracy comparison

具在较高的分类精度，但是在不同光谱数据的分类效果上，RF 表现出不同的效果，存在不稳定性；而 PSO_BP 在不同光谱数据上呈现出相似的分类精度且表现稳定。究其原因，RF 在识别过程中需要对一些超参数进行调整，例如树的数量等，不同的超参数对不同数据的适应能力有所差异，这也导致了 RF 在直立玉米秸秆识别精度上的不稳定性；而 PSO_BP 采用了 PSO 全局优化算法，能够自适应调整权重和偏置，避免了全局最优解，大大提高了分类器的泛化能力。

综上所述，直立秸秆识别的最优方案是使用 R'

光谱变换 + SDA 特征筛选 + PSO_BP 分类器的方法。

4 讨论

在原始光谱曲线中,直立玉米秸秆同干枯草的波形相似,干枯草的反射率大于直立玉米秸秆,这是因为干枯草内部也含有木质素和纤维素,但在测量时整个视场全是干枯草,亮度高,而测量的直立玉米秸秆光谱为冠层和土壤背景的混合光谱,存在光谱吸收和多次反射,导致直立玉米秸秆的反射率低于干枯草。由于本文主要考虑直立秸秆及其相似地物种类的多样性,对于秸秆残茬地的光谱曲线选取的是秸秆残茬覆盖度较低的区域,所以与直立秸秆光谱曲线相似度较低。秸秆残茬覆盖度近年来一直是秸秆研究的热点[31-32],二者光谱都是木质素及纤维素起主导作用,短波红外波段光谱存在相似。因遥感视场对象及影响因素不同,二者光谱规律有差异,但作物残渣秸秆覆盖度遥感理论、方法可为秋冬季田间玉米秸秆遥感识别开拓思路。

不同数据集上的分类结果对比表明,对多光谱数据进行敏感波段的提取,研究发现多数特征波段位于短波红外区域,同时也符合直立秸秆特征光谱的产生机制[33-34]。反射曲线是地物内部结构和组成相互作用的结果,秋冬季直立玉米秸秆干枯,叶片和茎秆存在较多的木质素和纤维素,这是直立玉米秸秆在生化来源上与其他地物的不同之处[35]。小麦等光合作物的叶黄素(类胡萝卜素、叶黄素)对可见光的吸收很强,因此可见光的反射率很低。在近红外波段,叶片内细胞壁-空气界面的多次散射产生高反射率。对于直立玉米秸秆和干枯草等非光和作物,1.9 nm 处的特征可归因于水分吸收,2.1 nm 的特征与木质素和纤维素有关,但在土壤光谱中不可见,2.2 nm 的特征与土壤的粘土矿物有关,但在非光和作物光谱中不存在,可以判断,受木质素和纤维素的影响,直立玉米秸秆在短波红外区域与其他地物表现出不同的反射特征,这一发现与文献[34-35]在秸秆残茬特性的研究发现是类似的。

利用光谱变换对 9 类光谱数据进行深度处理,可以增强光谱特征,有助于放大直立秸秆与其相似地物的光谱变化,提地物间的可分性[36]。光谱微分变换可以消除部分大气影响,平滑土壤、阴影等植被背景的干扰[22]。倒数的对数法能进一步放大直立玉米秸秆与其他地物光谱曲线间的细小差异[23]。连续统去除变换可以消除噪声,增强地物光谱吸收和反射特性[24]。本实验采用不同的光谱变换来改变光谱数据的形式,再通过 2 种特征提取方法来提取最有效的特征,有利于直立秸秆与其相似地物的高效识别。

本文主要基于特征波段提取敏感波段构建数据集,相关研究表明,光谱指数在地物识别过程中也具有重要的作用,在后续研究中,将针对本文中的敏感波段进行波段组合构建光谱指数,并结合现有的光谱指数,通过少数特征变量达到更加快速准确识别直立玉米秸秆的目的。另外本研究仅针对特定的研究区和特定数据进行了验证,缺乏在其他地区的验证与优化,不同数据源、地理环境、气候条件下的秸秆识别能力还有待验证,为了增强结果的鲁棒性,后续研究将考虑在多个研究区进行验证,获取不同地区的实测高光谱,无人机、卫星高光谱等数据,进行跨地区的农田玉米直立玉米秸秆识别实验,以确保研究结果的适用性,为防止秸秆焚烧、指导秸秆综合利用及实际农业生产决策提供可靠信息。

5 结论

(1)本研究基于地面高光谱数据引入光谱变换和特征波段提取方法对直立玉米秸秆及其相似地物的光谱曲线进行分析,筛选出适合直立玉米秸秆识别的敏感波段和光谱数据,并找出最佳特征提取方法和分类器,证明了高光谱数据在秋冬季未离田直立玉米秸秆识别场景应用的可行性。

(2)敏感波段多分布于短波红外区域,证明短波红外区域是识别直立玉米秸秆的敏感波段区域,直立玉米秸秆与其他相似性地物存在光谱可分性。

(3)变换光谱数据识别效果高于原始光谱数据,最优光谱数据为 R'数据,利用 SDA 筛选的特征波段识别效果更准确。

(4)4 种分类器都能够满足直立玉米秸秆的识别要求,其中 PSO_BP 的识别效果最稳定。

参 考 文 献

[1] 张景源, 杨绪红, 涂心萌, 等. 2014—2018 年中国田间秸秆焚烧火点的时空变化[J]. 农业工程学报, 2019, 35(19): 191-199.
ZHANG Jingyuan, YANG Xuhong, TU Xinmeng, et al. Spatio-temporal change of straw burning fire points in field of China from 2014 to 2018[J]. Transactions of the CSAE, 2019, 35(19): 191-199. (in Chinese)

[2] 胡婵娟, 文春波, 任杰, 等. 秸秆资源化利用理论与实践[M]. 北京: 中国农业科学技术出版社, 2019.

[3] 姜海玲, 杨胜杰, 张秀华, 等. 秸秆焚烧遥感监测及空气污染防治对策[J]. 湖北农业科学, 2017, 56(20): 3841-

3844.
JIANG Hailing, YANG Shengjie, ZHANG Xiuhua, et al. Remote sensing monitoring of straw burning and strategies for air pollution prevention and control[J]. Journal of Hubei Agricultural Sciences, 2017, 56(20): 3841 - 3844. (in Chinese)
[4] SHOLIHAH R I, TRISASONGKO B H, SHIDDIQ D, et al. Identification of agricultural drought extent based on vegetation health indices of landsat data: case of Subang and Karawang, Indonesia[J]. Procedia Environmental Sciences, 2016, 33: 14 - 20.
[5] 田庆久, 王玲, 包颖, 等. 基于 HJ - 1B 卫星的作物秸秆提取及其焚烧火点判定模式[J]. 中国科学: 信息科学, 2011, 41(增刊 1): 117 - 127.
TIAN Qingjiu, WANG Ling, BAO Ying, et al. Crop straw extraction and burning spot detection model based on HJ - 1B satellite[J]. Science China: Information Sciences, 2011, 41(Supp. 1):117 - 127. (in Chinese)
[6] 李存军, 周静平, 淮贺举, 等. 农田玉米秸秆卫星遥感提取方法及装置: 202110220236.6[P]. 2023 - 11 - 30.
[7] ZHOU J, GU X, LIU C, et al. A new approach to extract the upright maize straw from Sentinel - 2 satellite imagery using new straw indices[J]. Computers and Electronics in Agriculture, 2024, 216: 108506.
[8] 王肖霞, 杨风暴, 梁若飞, 等. 基于分割区域及特征相似度的玉米田遥感图像分类方法[J]. 图学学报, 2016, 37(3): 428 - 433.
WANG Xiaoxia, YANG Fengbao, LIANG Ruofei, et al. Remote sensing image classification method for maize fields based on segmentation regions and feature similarity[J]. Journal of Graphics, 2016, 37(3): 428 - 433. (in Chinese)
[9] 张凝, 杨贵军, 赵春江, 等. 作物病虫害高光谱遥感进展与展望[J]. 遥感学报, 2021, 25(1): 403 - 422.
ZHANG Ning, YANG Guijun, ZHAO Chunjiang, et al. Progress and prospects of crop pest and disease hyperspectral remote sensing[J]. Journal of Remote Sensing, 2021, 25(1): 403 - 422. (in Chinese)
[10] MIRZAEI M, MAROFI S, ABBASI M, et al. Scenario-based discrimination of common grapevine varieties using in-field hyperspectral data in the western of Iran[J]. International Journal of Applied Earth Observation and Geoinformation, 2019, 80: 26 - 37.
[11] ZHOU B, LI H, XU F. Analysis and discrimination of hyperspectral characteristics of typical vegetation leaves in a rare earth reclamation mining area[J]. Ecological Engineering, 2022, 174: 106465.
[12] 竞霞, 闫菊梅, 邹琴, 等. 基于 CC - MPA 特征优选算法的小麦条锈病遥感监测[J]. 农业机械学报, 2022, 53(9): 217 - 225, 304.
JING Xia, YAN Jumei, ZOU Qin, et al. Remote sensing monitoring of wheat stripe rust based on CC - MPA feature optimization algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 217 - 225, 304. (in Chinese)
[13] JIN X, JIE L, WANG S, et al. Classifying wheat hyperspectral pixels of healthy heads and Fusarium head blight disease using a deep neural network in the wild field[J]. Remote Sensing, 2018, 10(3): 395.
[14] CUI L, ZUO X, DOU Z, et al. Plant identification of Beijing Hanshiqiao wetland based on hyperspectral data[J]. Spectroscopy Letters, 2021, 54(5): 381 - 394.
[15] ZHOU B, LI H, XU F. Analysis and discrimination of hyperspectral characteristics of typical vegetation leaves in a rare earth reclamation mining area[J]. Ecological Engineering, 2022, 174: 106465.
[16] PU R, LIU D. Segmented canonical discriminant analysis of in situ hyperspectral data for identifying 13 urban tree species[J]. International Journal of Remote Sensing, 2011, 32(8): 2207 - 2226.
[17] 王浩, 秦来安, 靖旭, 等. 基于光谱分析的罂粟识别研究[J]. 量子电子学报, 2019, 36(2): 151 - 155.
WANG Hao, QIN Laian, JING Xu, et al. Study on poppy identification based on spectral analysis[J]. Journal of Quantum Electronics, 2019, 36(2): 151 - 155. (in Chinese)
[18] TANG N, SUN J, YAO K, et al. Identification of *Lycium barbarum* varieties based on hyperspectral imaging technique and competitive adaptive reweighted sampling-whale optimization algorithm-support vector machine[J]. Journal of Food Process Engineering, 2021, 44(1): e13603.
[19] LI X, WANG H, LI X, et al. Identifying degraded grass species in Inner Mongolia based on measured hyperspectral data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(12): 5061 - 5075.
[20] LIU H, WANG H, LI X, et al. Identification of constructive species and degraded plant species in the temperate typical grassland of Inner Mongolia based on hyperspectral data[J]. Agriculture, 2023, 13(2): 399.
[21] 刘宏明, 刘玉娟, 仲志成, 等. 一种油田原油含水率的近红外光谱检测与分析方法[J]. 光谱学与光谱分析, 2021, 41(2): 505 - 510.
LIU Hongming, LIU Yujuan, ZHONG Zhicheng, et al. Near-infrared spectroscopic detection and analysis method for water content in crude oil in oilfields[J]. Spectroscopy and Spectral Analysis, 2021, 41(2): 505 - 510. (in Chinese)
[22] BRITZ R, BARTA N, SCHAUMBERGER A, et al. Spectral-based classification of plant species groups and functional plant parts in managed permanent grassland[J]. Remote Sensing, 2022, 14(5): 1154.
[23] 冯子恒, 李晓, 段剑钊, 等. 基于特征波段选择和机器学习的小麦白粉病高光谱遥感监测[J]. 作物学报, 2022, 48(9): 2300 - 2314.
FENG Ziheng, LI Xiao, DUAN Jianzhao, et al. Hyperspectral remote sensing monitoring of wheat powdery mildew based on

feature band selection and machine learning[J]. Acta Agronomica Sinica, 2022, 48(9): 2300 - 2314. (in Chinese)
[24] YANG H, DU J. Classification of desert steppe species based on unmanned aerial vehicle hyperspectral remote sensing and continuum removal vegetation indices[J]. Optik, 2021, 247: 167877.
[25] 王卓卓, 何英彬, 罗善军, 等. 基于冠层高光谱数据与马氏距离的马铃薯品种识别[J]. 江苏农业学报, 2018, 34(5): 1036 - 1041.
WANG Zhuozhuo, HE Yingbin, LUO Shanjun, et al. Potato variety identification based on canopy hyperspectral data and Mahalanobis distance[J]. Journal of Jiangsu Agricultural Sciences, 2018, 34(5): 1036 - 1041. (in Chinese)
[26] JIAO Y, LI Z, CHEN X, et al. Preprocessing methods for near-infrared spectrum calibration[J]. Journal of Chemometrics, 2020, 34(11): e3306.
[27] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45: 5 - 32.
[28] CHEN Y, JIANG H, LI C, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(10): 6232 - 6251.
[29] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735 - 1780.
[30] LI G, LI J, LIU Y, et al. A near-infrared CO_2 detection system for greenhouse gas based on PCA - DNN[J]. Microwave and Optical Technology Letters, 2023, 65(5): 1468 - 1474.
[31] 黄晋宇, 刘忠, 万炜, 等. 基于土壤异质背景的玉米秸秆覆盖度遥感反演[J]. 应用生态学报, 2020, 31(2): 474 - 482.
HUANG Jinyu, LIU Zhong, WAN Wei, et al. Remote sensing inversion of maize straw coverage based on soil heterogeneous background[J]. Chinese Journal of Applied Ecology, 2020, 31(2): 474 - 482. (in Chinese)
[32] XIANG X, DU J, JACINTHE P A, et al. Integration of tillage indices and textural features of Sentinel - 2A multispectral images for maize residue cover estimation[J]. Soil and Tillage Research, 2022, 221: 105405.
[33] XU Y, WANG J, XIA A, et al. Continuous wavelet analysis of leaf reflectance improves classification accuracy of mangrove species[J]. Remote Sensing, 2019, 11(3): 254.
[34] NAJAFI P, NAVID H, FEIZIZADEH B, et al. Remote sensing for crop residue cover recognition: a review[J]. Agricultural Engineering International: CIGR Journal, 2018, 20(1):63 - 69.
[35] DAUGHTRY C S T, HUNT JR E R. Mitigating the effects of soil and residue water contents on remotely sensed estimates of crop residue cover[J]. Remote Sensing of Environment, 2008, 112(4): 1647 - 1657.
[36] YAMANO H, CHEN J, TAMURA M. Hyperspectral identification of grassland vegetation in Xilinhot, Inner Mongolia, China [J]. International Journal of Remote Sensing, 2003, 24(15): 3171 - 3178.