

激光与光电子学进展

基于高光谱数据的典型地物分类识别方法研究

徐达, 潘军, 蒋立军*, 曹宇

吉林大学地球探测科学与技术学院, 吉林 长春 130026

摘要 为探究典型地物间光谱特征差异以及针对传统光谱分类方法预处理复杂、精度较低等问题,以大豆、玉米、水稻和裸土 4 类地物为例,充分挖掘变量在分类中的重要性,进行深度学习方法与传统方法的对比分析与验证。首先利用连续投影算法(SPA)进行基础波段筛选,对比分析在原始光谱、特征波段以及部分特征波段条件下一维卷积神经网络(1DCNN)和长短时记忆人工神经网络(LSTM)两种深度学习模型的分类精度,探究特征波段对原始光谱的信息承载能力;然后针对错分问题,采用进阶式波段筛选方法,在基础变量组合条件下,对各类地物错分样本进行再次训练,如此循环,直到分类精度无明显增加,研究错分样本的光谱特征及错分规律;最后比较不同方法的分类精度。研究结果表明:基础波段筛选可以剔除光谱数据中大量的冗余信息,简化网络结构,提高模型效率;进阶式波段筛选方法可以递进增补针对错分样本的有效光谱信息,对提高传统方法的分类精度具有较大意义;在不经过光谱变换等预处理步骤时,深度学习方法也能取得较高的分类精度,明显优于传统方法,但训练过程较为复杂,可解释性较差。

关键词 高光谱; 分类识别; 深度学习; 波段筛选

中图分类号 O433 文献标志码 A

DOI: 10.3788/LOP222050

Typical Feature Classification and Identification Method Based on Hyperspectral Data

Xu Da, Pan Jun, Jiang Lijun*, Cao Yu

Key College of Geo-Exploration Science and Technology, Jilin University, Changchun 130026, Jilin, China

Abstract To investigate the differences of spectral features among typical features and to address the complicated preprocessing and low accuracy of traditional spectral classification methods, this study considers four features: soybean, corn, rice, and bare soil, as examples, comprehensively investigates the importance of variables in classification, and conducts a comparative analysis and validation of deep learning and traditional methods. First, we use the continuous projection algorithm (SPA) for the baseband screening and compare and analyze the classification accuracy of two deep learning models: the one-dimensional convolutional neural network (1DCNN) and the long short-term memory artificial neural network (LSTM), under the conditions of the original spectrum, the feature band, and the partial feature band, to evaluate the information-carrying capacity of the feature band to the original spectrum. Then, for the misclassification problem, we use the progressive band-screening method to train the misclassified samples again with a combination of basic variables until the classification accuracy does not increase significantly, and analyze the spectral characteristics and misclassification behavior of the misclassified samples. Finally, we compare the classification accuracy of different methods. The results show that the basic band screening can eliminate a large amount of redundant information in the spectral data, simplify the network structure, and improve the model efficiency. The advanced band-screening method can incrementally add effective spectral information for misclassified samples, which helps improve the classification accuracy of traditional methods. The deep learning method can also achieve high classification accuracy without preprocessing steps such as spectral transformation, which is significantly better than the traditional method. However, its training process is more complicated and less interpretable than that of the traditional method.

Key words hyperspectrum; classification identification; deep learning; wave filter

1 引言

随着光谱学的不断发展,人们对地物光谱属性、特

征的认知也在不断深入,许多隐藏在狭窄光谱范围内的地物特性逐渐得以发现^[1]。高光谱数据具有光谱范围广、光谱分辨率高、数据量大等特点^[2],更容易获取

收稿日期: 2022-06-11; 修回日期: 2022-07-15; 录用日期: 2022-07-22; 网络首发日期: 2022-08-02

基金项目: 国家民用空间基础设施陆地观测卫星共性应用支撑平台(CASPLOS-CCSI)

通信作者: *lijun@jlu.edu.cn

地物的局部精细信息,对光谱细节特征具有良好的表现能力。自从高光谱技术诞生以来,已有大批学者在农作物识别与分类、土壤重金属污染监测、植被识别与分类等高光谱分类领域进行广泛研究^[3-10]。如何探究不同样本间光谱特征差异以及提高分类识别精度是当前高光谱分类领域需解决的重要问题。

针对上述科学问题,诸多学者分别开展了基于对原始光谱数据进行光谱变换、平滑等预处理技术,然后通过主成分分析、支持向量机等传统方法应用于高光谱分类识别研究。例如:Banskota等^[11]使用小波离散变换分析对3种针叶树分类效果进行评价,分类方法采用逐步判别法,最后的分类精度达到了74.2%;Pu等^[12]利用高光谱数据识别阔叶树种,对原始光谱进行归一化、导数等5种光谱变换,使用非线性人工神经网络(ANN)和线性判别分析(LDA)2种算法来鉴定11种阔叶物种,结果表明2种算法均取得较好精度,总体准确率为86.3%~87.8%;曾帅等^[13]实地测取了鄱阳湖湿地6种优势种植物的反射光谱曲线,运用导数、包络线等方法对光谱进行变换分析,提取了各项光谱特征参数并对植物进行分类识别,总体分类精度为85.5%。上述研究表明,传统方法可以应用于高光谱分类识别研究,但预处理方法有很多种,如何选择和组合这些方法会对分类结果产生很大影响,由此造成的耗时长、分类精度较低等问题一直难以解决。

随着数据集规模的增加和人工智能(AI)快速的发展,机器学习(ML)在各个科学领域的应用越来越流行^[14]。深度学习作为机器学习领域中一个新的研究方向,近年来也逐渐应用于光谱分类、光谱检测等领域中^[15-20]。Le等^[21]利用深度学习的卷积神经网络(CNN)结合极限学习机(ELM)建立CNN-ELM分类模型,对不同煤样品进行分类识别,结果表明CNN-ELM模型优于PCA和SVM分类方法,分类精度达到96.51%;王璨等^[22]将CNN用于近红外光谱预测土壤含水率,结果表明在训练样本达到一定数量时,CNN预测精度高于BP、PLSR和LSSVM等3种传统模型;Rong等^[23]通过构建一维CNN实现不同桃品种的多鉴别,准确率达到94.4%。

综上所述,随着成像光谱仪器的广泛应用,利用光谱数据进行物质分类与识别已经成为一项重要的研究内容,研究不同分类算法对最终的目标识别准确度具有重要意义。目前现有研究中主要分为传统方法和深度学习方法,传统方法存在耗时长、分类精度较低等问题,深度学习方法能够简化预处理步骤,取得较高精度,但大多数研究只进行单次训练,并没有针对错分样本进行精细研究,很难从光谱特征分析的角度解释分类结果。

为此,本文通过研究不同地物的光谱反射率数据集,以错分样本为核心,进行CNN和长短时记忆(LSTM)人工神经网络2种深度学习方法与反向传播

(BP)神经网络和K-Nearest Neighbor(KNN)2种传统方法的对比分析与验证。首先,利用连续投影算法(SPA)进行基础波段筛选,探究特征波段对原始光谱的信息承载能力;然后,针对错分样本进行精细分析,采用进阶式波段筛选方法,递进增补有效光谱信息,以改进模型的精度;最后,比较不同方法的分类精度。由此探究不同地物间光谱特征的差异,并建立分类精度更高、典型的地物高光谱分类识别模型。

2 实验数据与分析

2.1 研究区域与样本

本次实验所选区域为黑龙江省双鸭山市友谊农场,场区地处三江平原腹部,地势平缓、土地连片,东西长为56 km,南北宽为44 km,区域内总控面积1888 km²,东与宝清县为邻,西与集贤县接壤,南依双鸭山市,北临富锦市,距宝清县87 km、集贤县64 km、双鸭山市74 km、富锦市33 km、同江市140 km、佳木斯市123 km。友谊农场耕地面积110429公顷,下辖11个农业管理区,人口10.26万,建场以来已累计生产粮食1.714×10¹⁰ kg。以农业为主,兼多种经营。粮食作物有大豆、玉米、水稻等,经济作物有甜菜、葵花籽、白瓜籽、烤烟等。

实验团队于2021年5月17日—22日和6月18日—23日在友谊农场进行光谱测量实验。测量地物为玉米、大豆和水稻,其中5月由于播种时间较短,玉米、大豆在土壤中属于刚出芽的状态,因此将5月的玉米和大豆样本划分为裸土类别。共选取697个样本,其中大豆204个样本、玉米190个样本、水稻40个样本、裸土263个样本。

2.2 仪器设备与采集方法

本次测量使用SEI便携式多功能地物光谱仪,仪器编号为SEI SR-8800 1310,其光谱测量范围覆盖近紫外-可见光-近红外波段。SR-8800型地物光谱仪全部使用固定全息光栅和全线阵列光学探测器,波段范围为350~2500 nm,分别由3个探测器组成:1个512单元的硅阵列探测器,用于可见光和部分近红外(350~1000 nm)波段;2个256单元InGaAs阵列制冷探测器,用于1000~2500 nm的SWIR波段。该光谱仪的所有控制系统都内置在RS-8800的机身中,使用IOS/Android系统的手机或平板等设备都可以无线连接并控制该光谱仪进行数据采集。仪器由专用的大容量锂离子电池供电,室内也可使用准用的电源适配器为设备供电。

光谱测量在野外进行,选择地表覆盖均匀且场地最短边长度不小于50 m的人工或天然场地为本次反射率测量场地。对基本采样单元采用十字五点采样法进行光谱采集,光谱数据采集方案包括光谱仪操作终端设置、白板标定、地物测量、数据备份等工作。测量了大豆、玉米、水稻和裸土的反射率光谱并拍照记录各类地物表面状态,如图1所示。测量时,光谱仪探头距




图 1 4 类地物表面状态。(a)大豆;(b)玉米;(c)水稻;(d)裸土

Fig. 1 Surface states of four types of features. (a) Soybean; (b) corn; (c) rice; (d) bare soil

离地物 1 m, 因此采集到的大豆、玉米光谱为叶片和土壤的混合光谱, 水稻光谱为叶片和水体的混合光谱。

2.3 光谱预处理

对采集到的 4 类地物原始光谱数据进行分析, 如图 2 所示。波长范围在 350~1800 nm 内, 各个地物光谱曲线较为平滑, 没有明显的光谱噪声, 在波长为 1800 nm 附近存在严重的噪声, 这是由于在波长为 1800 nm 处存在水汽吸收通道, 与地物的含水量有关。此外, 由于测量在野外进行, 天气环境和操作的影响导致在波长为 1800 nm 之后的光谱信息有较大的波动且含有噪声数据。如果采用全波段光谱数据进行后续分析处理, 会对所建分类模型的精度产生极大影响, 导致模型不可靠。因此, 选择采用波长范围在 350~1800 nm 的光谱数据进行相关分析, 为了简化传统方法采用一些预处理步骤, 不再对光谱数据进行其他变换, 直接利用截取后的光谱数据进行后续分析处理。

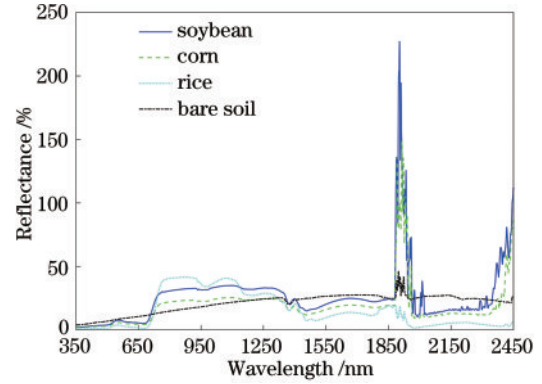


图 2 350~2500 nm 四类地物平均反射率光谱曲线

Fig. 2 Average reflectance spectral curves of four types of features in the range of 350–2500 nm

2.4 光谱特征分析

波长范围在 350~1800 nm 的 4 类地物光谱数据, 如图 3 所示。由图 3 可知, 大豆、玉米和水稻等 3 种地

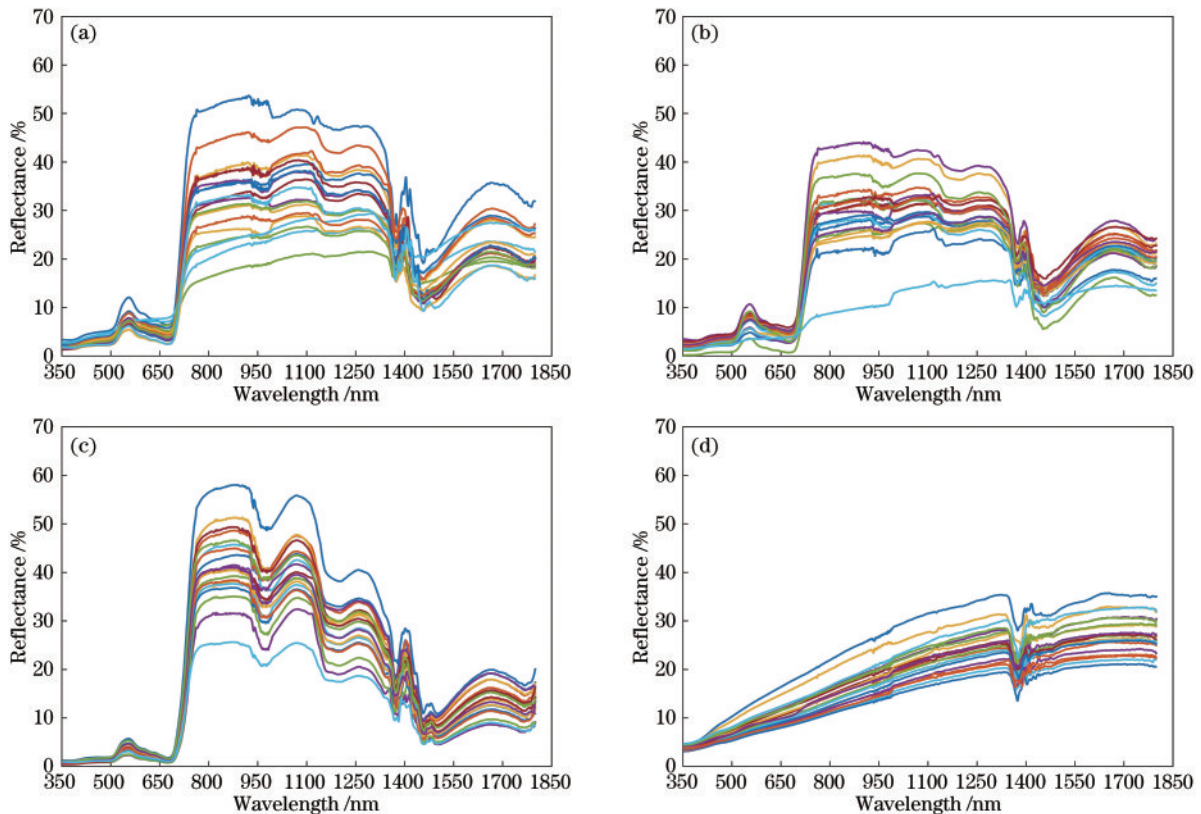


图 3 350~1800 nm 四类地物部分样本光谱曲线(20 条)。(a)大豆;(b)玉米;(c)水稻;(d)裸土

Fig. 3 Spectral curves of some samples of four types of features from 350–1800 nm (20 bars). (a) Soybean; (b) corn; (c) rice; (d) bare soil

物的反射光谱曲线走势一致,同其他绿色植被一样,在波长为 670 nm 的红光波段有一处吸收带,其反射率较低;在波长为 550 nm 的绿光波段有一个明显的反射峰;在波长为 700 nm 处反射率急速增高,至波长为 1100 nm 的近红外波段反射率达到高峰,这是植被的独有特征;在波长为 1300 nm 之后,因绿色植物含水量的影响,吸收率增大,反射率大大下降,在水的吸收带形成低谷。在部分波段范围内,3 种地物的光谱曲线存在一些差异,例如波长范围在 450~650 nm 内,水稻的光谱反射率最低,这是由于测量的水稻光谱为叶片和水体的混合光谱,水的反射率较低。大豆和玉米在整个波段范围内光谱反射率相近,二者难以区分。裸土的光谱曲线比较平滑,没有明显的峰值和谷值,但在整个波段范围内,裸土的反射率与其他 3 种地物有较大部分的重合,容易出现混淆的现象。

3 结果与讨论

3.1 数据集划分

本次实验将数据集按 8:2 划分为训练集和测试集,如表 1 所示,各个样本随机选择。

表 1 数据集统计

Table 1 Data set statistics

Data set	Number of data	Soybean	Corn	Rice	Bare soil
Training set	557	164	151	32	210
Test set	140	40	39	8	53

3.2 特征波段选取

高光谱数据一些相邻波段之间存在着较强的相关性,导致光谱数据包含大量的冗余信息,如果直接将原始光谱数据输入到深度学习模型,可能会导致模型出现过拟合现象,严重影响模型的处理速度。因此,选择

使用 SPA 对原始光谱数据进行特征波段筛选,通过筛选后的少量波段信息承载原始高维信息。

3.2.1 SPA 原理

SPA 是前向特征变量选择方法。SPA 利用向量的投影分析,通过将波长投影到其他波长上,比较投影向量大小,以投影向量最大的波长为待选波长,然后基于矫正模型选择最终的特征波长。SPA 选择的是含有最少冗余信息及最小共线性的变量组合。该算法简要步骤如下^[24]:

记初始迭代向量为 $\mathbf{x}_{k(0)}$,需提取的变量个数为 N ,光谱矩阵为 J 列。

1) 任选光谱矩阵的 1 列(第 j 列),将建模集的第 j 列赋值给 \mathbf{x}_j ,记为 $\mathbf{x}_{k(0)}$ 。

2) 将未选入的列向量位置的集合记为 s :

$$s = \{j, 1 \leq j \leq J, j \neq \{k(0), k(1), \dots, k(n-1)\}\} \quad (1)$$

3) 分别计算 \mathbf{x}_j 对剩余列向量的投影:

$$\mathbf{P}_{xj} = \mathbf{x}_j - (\mathbf{x}_j^T \mathbf{x}_{k(n-1)}) \mathbf{x}_{k(n-1)} (\mathbf{x}_{k(n-1)}^T \mathbf{x}_{k(n-1)})^{-1}, j \in s \quad (2)$$

4) 提取最大投影向量的光谱波长:

$$k(n) = \arg \left(\max \left(\left\| \mathbf{P}_{(xj)} \right\| \right) \right), j \in s \quad (3)$$

5) 令 $\mathbf{x}_j = \mathbf{P}_{xj}, j \in s$ 。

6) $n = n + 1$,若 $n < N$,则按式(1)循环计算。

最后,提取出的变量为 $\{\mathbf{x}_{k(n)} = 0, 1, \dots, N - 1\}$ 。

对应每一次循环中的 $k(0)$ 和 N ,其中最小的均方根误差(RMSE)对应的 $k(0)$ 和 N 就是最优值。一般 SPA 选择的特征波长分数 N 不能很大。

3.2.2 特征波段集合

利用 SPA,根据 RMSE 最小化原则,选出最有效区分不同地物类型的特征波段,如图 4 所示。共选择 8 个波段,分别为 410 nm、542 nm、714 nm、734 nm、856 nm、1423 nm、1475 nm、1712 nm。

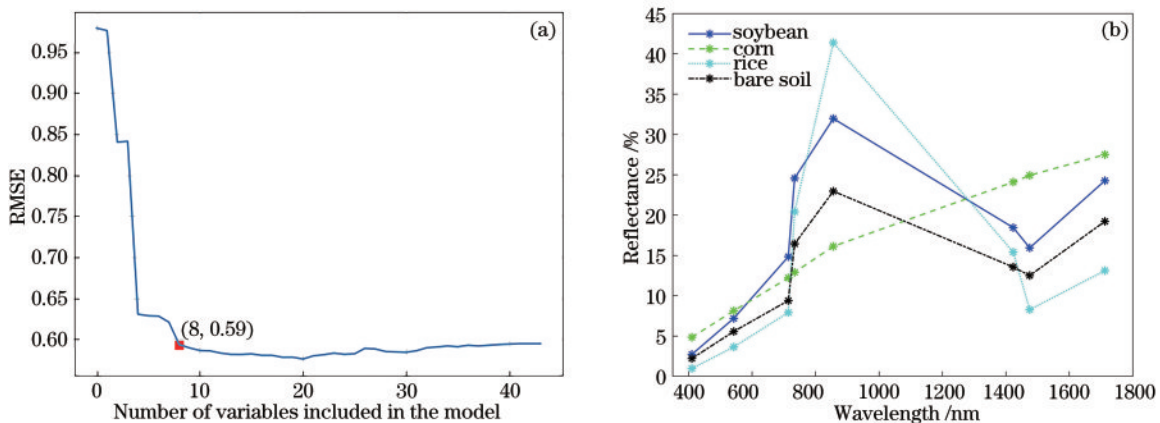


图 4 SPA 特征波段选择结果。(a)RMSE;(b)平均光谱反射率

Fig. 4 SPA feature band selection results. (a) RMSE; (b) average spectral reflectance

各类地物样本点在不同特征波段组合方式下的分布情况能够反映出各类地物在不同波段上的特征,可

以初步判断所筛选的特征波段能有效区分各类地物。以 4 类地物在 410 nm 波段和其他波段相互组合为例,

如图 5 所示, 4 类地物都表现出了不同特征: 其中大豆和玉米的样本点在各个波段上分布都较为分散, 且出现大量交集, 说明这两种地物的光谱特征相近, 仅凭筛选特征波段无法实现有效区分; 水稻和裸土的样本点出现聚集现象, 其中水稻的样本点与玉米的样本点有小部分重合

合, 裸土的样本点与大豆的样本点有小部分重合, 在分类时容易混淆。总体来看, 筛选出的特征波段能够有效代表 4 类地物的特征信息, 可以初步区分部分地物样本, 但效果并不理想, 尤其是难以区分大豆和玉米。因此, 需利用不同分类识别方法开展进一步研究。

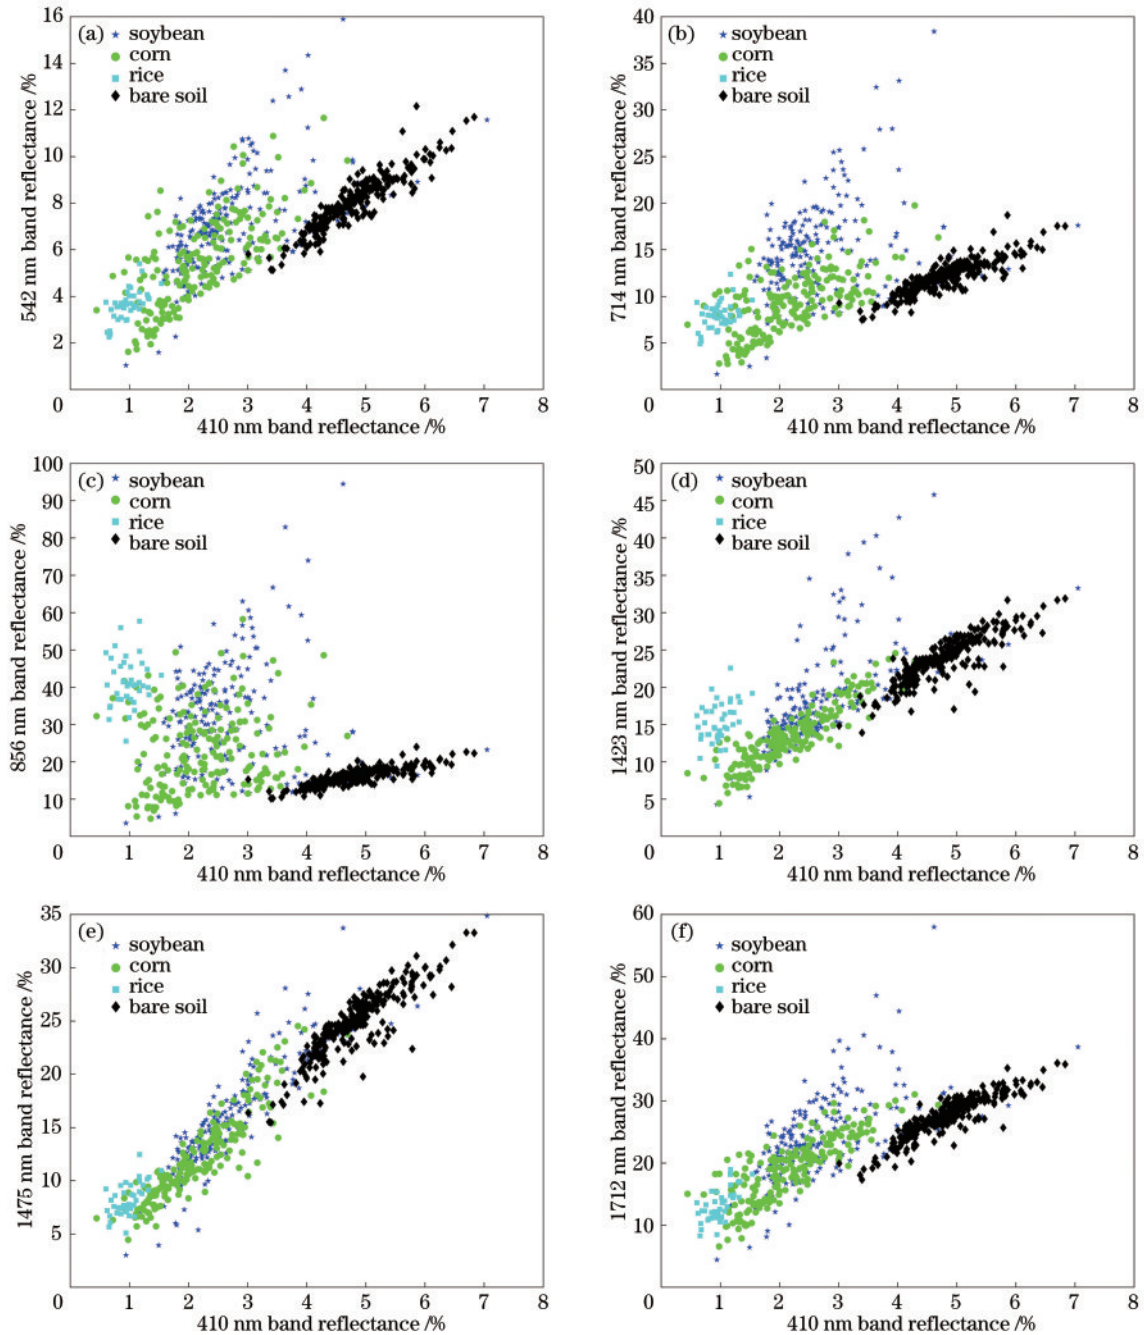


图 5 地物样本点分布。(a) 410 nm 和 542 nm; (b) 410 nm 和 714 nm; (c) 410 nm 和 856 nm; (d) 410 nm 和 1423 nm; (e) 410 nm 和 1475 nm; (f) 410 nm 和 1712 nm

Fig. 5 Distribution of feature sample points. (a) 410 nm and 542 nm; (b) 410 nm and 714 nm; (c) 410 nm and 856 nm; (d) 410 nm and 1423 nm; (e) 410 nm and 1475 nm; (f) 410 nm and 1712 nm

3.3 一维 CNN(1DCNN)

CNN 被广泛应用于图像检测、识别与分类领域, 为了能够适应 CNN 的结构, 在处理光谱数据时, 普遍做法是将一维光谱信息转换为二维光谱信息矩阵, 然

后再输入到网络中。为了降低识别时间, 以及判断筛选后的特征波段能否有效承载原始光谱信息和网络结构的变化。选择将原始光谱数据和经过特征波段筛选后的光谱数据分别直接输入到 1DCNN 中, 由于维度

的特点,1DCNN在训练中可以降低对样本数量的要求,实现更好的拟合。

3.3.1 1DCNN 网络结构

1DCNN可以很好地应用于传感器数据的时间序列分析(如加速度数据),也可以用于分析具有固定长度周期的信号数据(如音频信号)。针对光谱数据,提出了一种基于1DCNN的典型地物自动分类算法,如图6所示。以350~1800 nm地物光谱数据为例,初始输入为光谱变量,最终输出为地物分类结果。由于输入矢量是一维光谱数据,所以滤波器也选择一维矢量,利用光谱的局部窗口计算滤波器的卷积。CNN的结

构包括8个卷积层,每个卷积层的激活函数为ReLU(线性校正单元),每2个卷积层后面有一个最大池化层,池化核大小设置为2,目的是减少输出的复杂度和防止数据过拟合,最后一个卷积层后面有一个全局平均池化层,目的是取神经网络中两个权重的平均值,dropout层是为了防止模型出现过拟合现象,在输出之前随机失活一些神经元,最后以softmax损耗作为分类层对地物进行分类。为了传递更多的多尺度光谱详细信息,在网络路径上共享了不同大小的卷积核和不同数量的滤波器。

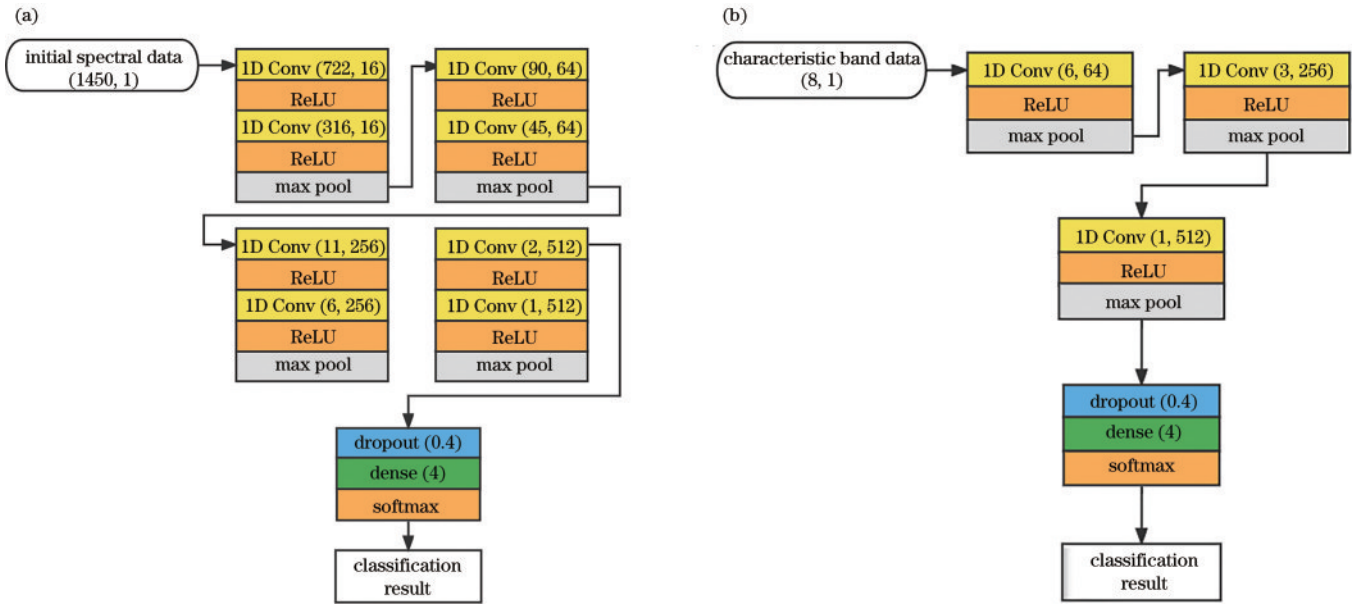


图6 结构图。(a)1DCNN;(b)1DCNN-SPA

Fig. 6 Structure diagrams. (a) 1DCNN; (b) 1DCNN-SPA

3.3.2 1DCNN 网络训练与测试

本实验将采集的557个训练集样本和140个测试集样本输入到搭建好的1DCNN中。训练集样本用于建立模型,测试集样本用于检验模型的可靠性和稳定性。模型的收敛程度和性能通过损失函数和分类精度来评价,如图7、图8所示。在训练过程中,使用Adam

优化器,其结合了Adagrad善于处理稀疏梯度和RMSprop善于处理非平稳目标等优点,能够不断寻找最优的梯度下降方向,加快模型收敛,学习率设置为0.0002。损失函数表示真实值和预测值之间的差距,是衡量神经网络性能的重要参考指标,其值越小,代表模型收敛效果越好,选择使用的是交叉熵损失函数。




图7 1DCNN模型训练结果。(a)损失函数;(b)分类精度

Fig. 7 1DCNN model training results. (a) Loss; (b) classification accuracy




图8 1DCNN-SPA 模型训练结果。(a)损失函数;(b)分类精度

Fig. 8 1DCNN-SPA model training results. (a) Loss; (b) classification accuracy

每次选取 32 个样本,最大迭代次数为 5000 次,网络基于 Python 编程语言的 Tensorflow. keras 框架来实现。所有参数的取值都是经过多次对比实验后选取的最优值。最终通过损失值、分类精度和模型耗时 3 个指标比较 2 种模型,如表 2 所示。

表 2 不同模型的分类型结果

Table 2 Classification results of different models

Model type	Loss	Classification accuracy /%	Model time consumption /min
1DCNN	0.19682	97.14	67.85
1DCNN-SPA	0.25248	95.71	42.42

由图 7(a)、图 8(a) 可知,前 1000 次迭代中,1DCNN 和 1DCNN-SPA 的分类损失值一直处于快速下降状态;迭代到 3000 次后,损失值虽然存在上下波动的情况,但一直维持在较低水平,说明 2 个模型均已达到较好的收敛状态。由图 7(b)、图 8(b) 可知,迭代到 3000 次后,2 个模型的分类型精度均已达到稳定状态,只存在较小幅度的波动情况。由表 2 可知,2 个模型的总体分类型精度相差无几,1DCNN-SPA 耗时远小于 1DCNN,且由图 6 可知,1DCNN-SPA 的网络层数更少、结构更简便。说明通过 SPA 筛选特征波段可以

在总体分类型精度无明显下降的情况下,剔除高光谱数据中大量冗余信息,简化模型结构,提高模型运行效率。

3.4 LSTM

传统的 RNN 随着时间的迭代,历史输入值对隐层的影响会逐渐削弱直至消失,出现梯度消失的问题。LSTM 是在 RNN 基础上改进的,只记住有效信息,遗忘掉无用信息,能更加有效地保留有效信息,这就是长期记忆特点,非常适用于处理序列问题。因此,选择使用 LSTM 来处理光谱数据。与 1DCNN 同理,将原始光谱数据和经过特征波段筛选后的光谱数据分别输入到 LSTM 中。

3.4.1 LSTM 网络结构

利用 LSTM 对原始光谱数据和经过特征波长选择后的光谱数据进行分类识别,将数据输入到输入层,经过隐含层操作后,输出层输出分类结果。

LSTM 采用重复单元链的形式,关键在于细胞的状态和穿过细胞的一条水平线。该细胞以一种特殊的方式交互,使网络能够记住历史信息。LSTM 通过输入门、输出门和遗忘门来保护和控制信息。图 9 描述了 LSTM 体系结构,图的右侧是一个 LSTM 单元格。




图9 LSTM体系结构

Fig. 9 LSTM architecture

3.4.2 LSTM 网络训练与测试

在本次实验中(以初始光谱数据为例),构建了一个包含 64 个神经元的隐含层,一个 dropout 层,一个由 128 个神经元组成的全连接层,激活函数为 ReLU,一个由 4 个神经元组成的全连接层,激活函数为 softmax,如

图 10 所示。使用 Adam 优化器进行优化,学习率设置为 0.0001。损失函数使用交叉熵损失函数。每次选取 32 个样本,最大迭代次数为 5000 次。模型的收敛程度和性能通过损失函数和分类精度进行评价,如图 11、图 12 所示。

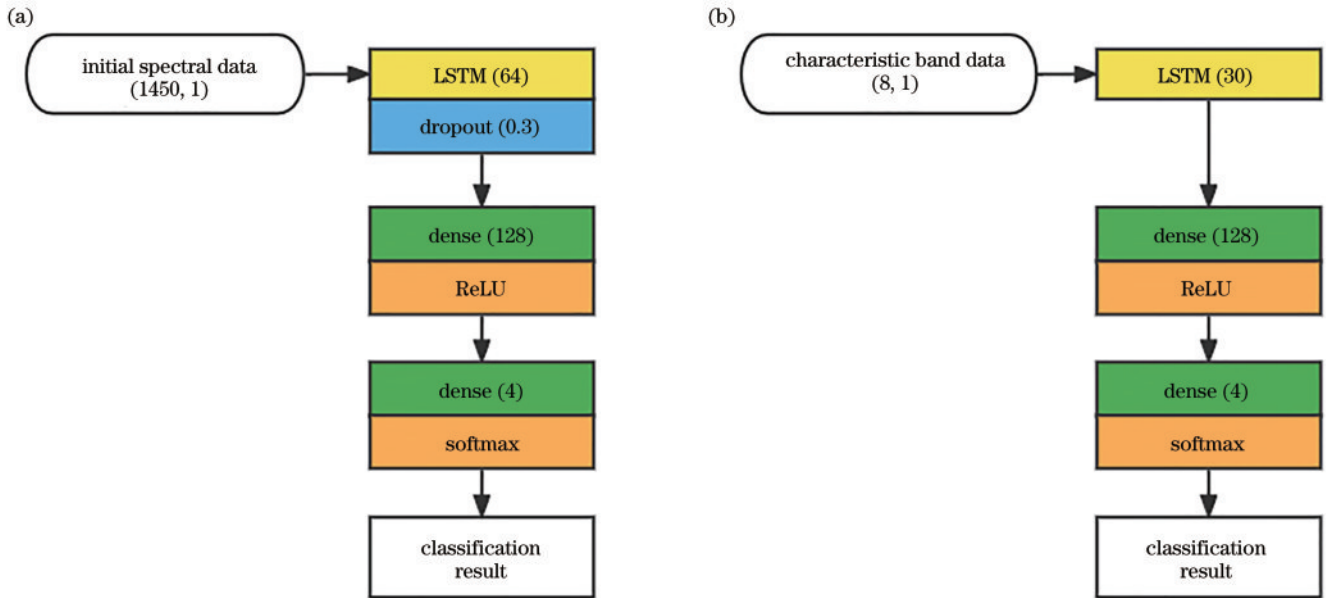


图 10 结构图。(a)LSTM;(b)LSTM-SPA

Fig. 10 Structure diagrams. (a) LSTM; (b) LSTM-SPA




图 11 LSTM 模型训练结果。(a)损失函数;(b)分类精度

Fig. 11 LSTM model training results. (a) Loss; (b) classification accuracy




图 12 LSTM-SPA 模型训练结果。(a)损失函数;(b)分类精度

Fig. 12 LSTM-SPA model training results. (a) Loss; (b) classification accuracy

网络基于 Python 编程语言的 Tensorflow.keras 框架来实现,所有参数的取值都是经过多次对比实验后选取的最优值。最终通过损失值、分类精度和模型耗时 3 个指标比较 2 种模型,如表 3 所示。

表 3 不同模型分类结果
Table 3 Classification results of different models

Model type	Loss	Classification accuracy /%	Model time consumption /min
LSTM	0.01100	99.29	13.78
LSTM-SPA	0.12020	98.57	12.12

由图 11(a)、图 12(a)可知,前 500 次迭代中,二者的分类损失处于快速下降阶段,迭代到 2000 次后,虽然 LSTM-SPA 的损失值存在上下波动情况,但已趋于稳定,说明 2 个模型均已达到收敛状态。由图 11(b)、图 12(b)可知,LSTM 的分类精度在 3000 次迭代后保持稳定,LSTM-SPA 的分类精度虽然一直存在上下波动情况,但 4000 次迭代后也趋于稳定。由表 3 可知,LSTM-SPA 的分类精度略低于 LSTM,但所耗时间小于 LSTM。说明通过 SPA 进行波段筛选后,可以在总体分类精度无较大损失的情况下,提高模型运行效率。

表 4 不同模型不同波段集合总体分类精度
Table 4 Overall classification accuracy of different models with different sets of bands

Model type	Remove very important band subsets /%	Remove subset of most important bands /%	Remove subset of less important bands /%	Remove subset of more important bands /%	8 feature band sets /%
BP	71.43	72.86	75.00	80.71	83.57
KNN	69.29	70.71	72.86	77.86	82.14
1DCNN	80.71	82.56	85.71	89.29	95.71
LSTM	82.14	83.57	87.14	90.00	98.57

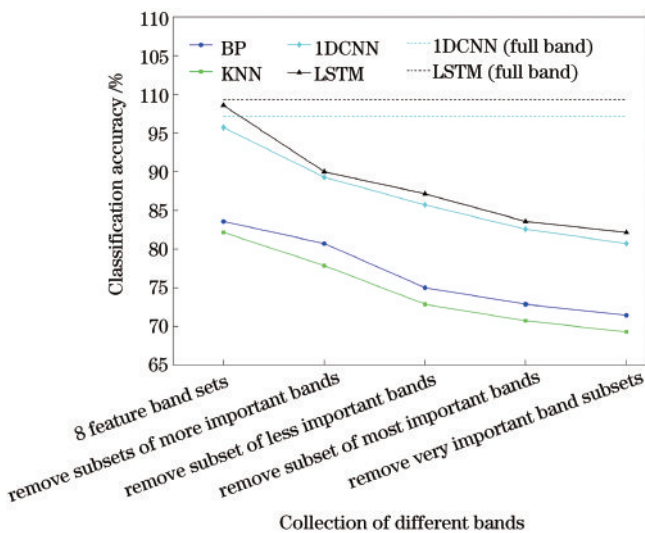


图 13 不同模型不同波段集合总体分类精度

Fig. 13 Overall classification accuracy of different models with different wave sets

3.5 不同模型的综合比较

选择目前研究中常用的 BP 神经网络和 KNN 算法进行对比实验,光谱数据使用经过 SPA 筛选后的数据。其中 BP 神经网络选择单隐层结构,KNN 算法的 k 值为 5。

3.5.1 不同特征波段组合的模型分类精度比较

将 SPA 筛选出的特征波段按重要性排序并编号:1~8 分别为 714 nm、542 nm、856 nm、1712 nm、410 nm、734 nm、1423 nm、1475 nm。将波段 1、2 定义为极重要波段;波段 3、4 定义为最重要波段;波段 5、6 定义为次重要波段;波段 7、8 定义为较重要波段。将去掉某个波段组合的子集(6 个波段)分别采用不同方法比较总体分类精度,如表 4 所示。以 350~1800 nm 全波段的 1DCNN 和 LSTM 总体分类精度作为参考,如图 13 所示。由图 13 可知,当去掉 8 个特征波段中某 2 个波段时,各个模型分类精度下降十分明显;当去掉的特征波段组合重要性越强时,模型分类精度降低越为严重;采用 8 个特征波段的模型总体分类精度与全波段的模型总体分类精度相比无较大损失。说明 SPA 筛选出的 8 个特征波段能够较好地代表 4 类地物的光谱特征,且每个特征波段都很重要,当特征波段不完整时,模型精度会严重降低。

3.5.2 各个模型的综合比较

总体分类精度、制图精度、用户精度和 Kappa 系数从不同方面描述了模型分类精度,是简便易行并具有统计意义的精度指标,见表 5、图 14。制图精度表示相对于参考数据中的任意一个随机样本,分类图上同一地点的分类结果与其相一致的条件概率;用户精度表示从分类结果中任取一个随机样本,其所具有的类型与地面实际类型相同的条件概率;总体分类精度是具有概率意义的一个统计量,表述的是对每一个随机样本,所分类的结果与参考数据所对应区域的实际类型相一致的概率;Kappa 系数是一个用于一致性检验的指标,也可以用于衡量分类的效果,能够惩罚模型的“偏向性”,其值越大表示分类结果越正确,模型越可靠。

由表 5、图 14 可知:1DCNN 和 LSTM 两种深度学习模型在各类地物的制图精度、用户精度以及模型总体分类精度和 Kappa 系数等精度指标方面都明显优于 BP 和 KNN 两种传统方法,说明 1DCNN 和 LSTM 两

表 5 不同模型 8 个特征波段下各类地物分类精度

Table 5 Classification accuracy of various types of features under 8 feature bands of different models

Model Type	Mapping accuracy / %				User accuracy / %				Overall accuracy / %	Kappa coefficient
	Soybean	Corn	Rice	Bare soil	Soybean	Corn	Rice	Bare soil		
BP	55.00	94.87	62.50	100	95.65	66.07	100	94.64	83.57	0.7613
KNN	62.50	76.92	87.50	100	75.76	68.18	100	94.64	82.14	0.7415
1DCNN	87.50	97.44	100	100	97.22	88.37	100	100	95.71	0.9383
LSTM	97.50	97.44	100	100	97.50	97.44	100	100	98.57	0.9794

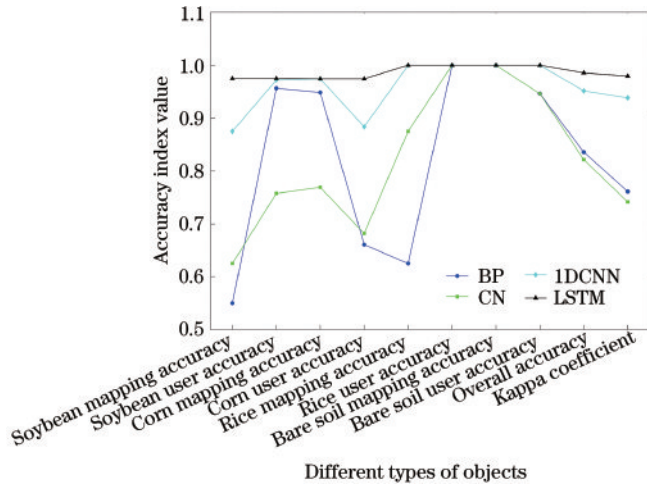


图 14 不同模型精度指标

Fig. 14 Different model accuracy metrics

种深度学习方法与传统方法相比具有更强的模型表达能力,能够自主学习、提取复杂光谱数据中隐藏的诊断性光谱特征,从而有效区分 4 类地物;LSTM 的各项精

度指标虽然优于 1DCNN,但相差不大,就实验数据而言,两种方法都适合处理光谱数据这样的序列数据。

3.6 各类地物分类结果分析

3.6.1 不同方法各类地物分类结果分析

混淆矩阵也称误差矩阵,能够清楚地表达模型正确分类和错误分类的个数,是衡量分类模型准确度最基本、最直观的方法,属于模型评判指标的一种。为此,构建了不同模型在 8 个特征波段下的分类混淆矩阵,如图 15 所示,直观地表达在每种方法下各类地物样本错分、漏分的情况。

由各类地物分类结果可知,4 种方法最常在玉米、玉米样本之间发生混淆,BP、KNN、1DCNN、LSTM 算法中大豆和玉米混淆样本占其全部错误样本的比例分别为 73.91%、84.00%、100%、100%。因此,重点对大豆、玉米样本进行精细分析,为了寻找错分规律,以每种错分情况最具有代表性的方法为例,绘制大豆、玉米分类正确与错误样本的光谱曲线,如图 16、图 17 所示。

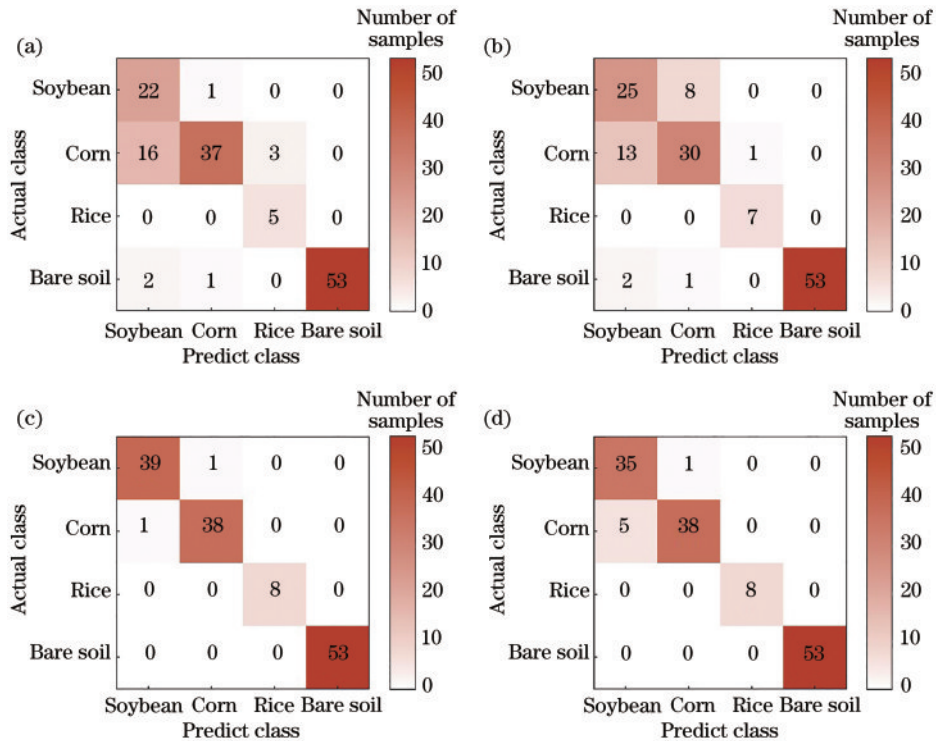


图 15 不同模型分类混淆矩阵。(a) BP; (b) KNN; (c) 1DCNN; (d) LSTM

Fig. 15 Confusion matrix for different model classifications. (a) BP; (b) KNN; (c) 1DCNN; (d) LSTM

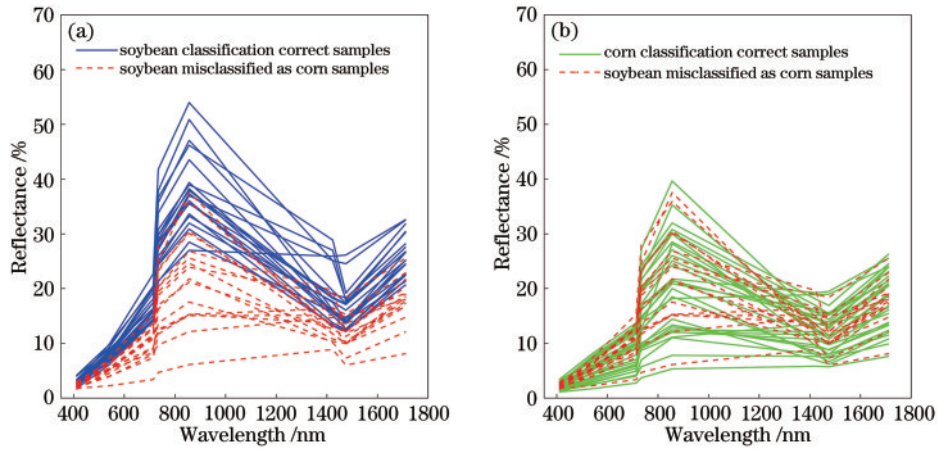


图 16 BP 光谱曲线。(a)大豆分类正确、大豆错分为玉米样本；(b)玉米分类正确、大豆错分为玉米样本

Fig. 16 BP Spectral curves. (a) Soybeans classified correctly, soybeans misclassified into corn samples; (b) corns classified correctly, soybeans misclassified into corn samples

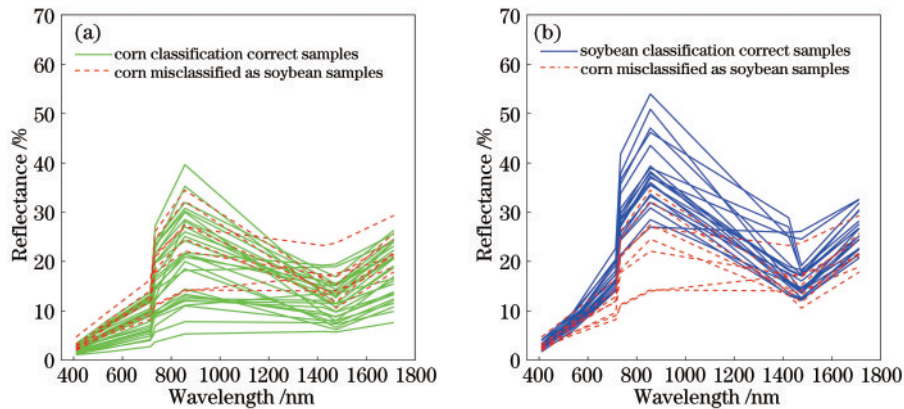


图 17 KNN 光谱曲线。(a)玉米分类正确、玉米错分为大豆样本；(b)大豆分类正确、玉米错分为大豆样本

Fig. 17 KNN Spectral curves. (a) Corns classified correctly, corns misclassified into soybean samples; (b) soybeans classified correctly, corns misclassified into soybean samples

由图 16 可知,大豆与玉米样本在这 8 个特征波段上光谱曲线走势一致,大豆样本的反射率要高于玉米样本。大豆错分为玉米的样本与大豆分类正确样本相比,其中 2 个样本在 856 nm 波段处无反射峰,2 个样本在 856 nm 波段之后下降较为缓慢,其余错误样本与大豆分类正确样本的光谱特征在这 8 个特征波段范围内并无明显区别,但反射率与大豆分类正确样本相比都偏低,更贴近玉米样本的反射率,因此发生混淆。

由图 17 可知,玉米错分为大豆样本在 714 nm 波段处并没有明显的拐点,在 856 nm 波段峰值过后,下降速度较慢,在 1423 nm 波段之后反射率明显偏高,更贴近大豆样本,光谱曲线走势与大豆相近。

3.6.2 进阶式波段筛选方法

针对大豆和玉米样本大量混淆的现象,采用进阶式波段筛选方法,针对每阶段波段筛选后 4 种方法大豆和玉米混淆的样本进行详细研究,通过不断引入新的特征波段进行错分的改进。以大豆和玉米样本的总体分类精度为评价指标,当总体分类精度不再增长或

增长缓慢时,停止特征波段筛选。

共进行 4 个阶段的波段筛选,从第 2 阶段起,每阶段波段筛选针对前一阶段波段筛选后 4 种方法大豆和玉米混淆的样本,利用 SPA 筛选出新的特征波段,与之前的特征波段联合组成新的特征波段集合,并利用 4 种算法对大豆和玉米样本进行分类识别,以 BP、KNN 算法为例,分别绘制在不同阶段特征波段集合下,大豆和玉米分类正确与错误样本的光谱曲线,如图 18、图 19 所示。

由图 18 可知,在低阶波段筛选时,大豆错分的样本与大豆分类正确样本相比反射率均偏低,与玉米样本的反射率相似。随着特征波段的增加,错分样本中相对高反射率的样本逐渐分类正确,只剩下个别低反射率的样本与玉米样本贴近,难以区分。

由图 19 可知,在低阶波段筛选时,KNN 算法将玉米错分为大豆的样本在 714 nm 波段处并没有明显的拐点,部分样本在 856 nm 波段峰值过后,反射率下降速度较慢,与大豆样本相似。随着特征波段的增加,在波长范围 856~1370 nm 内反射率下降较快,以及在

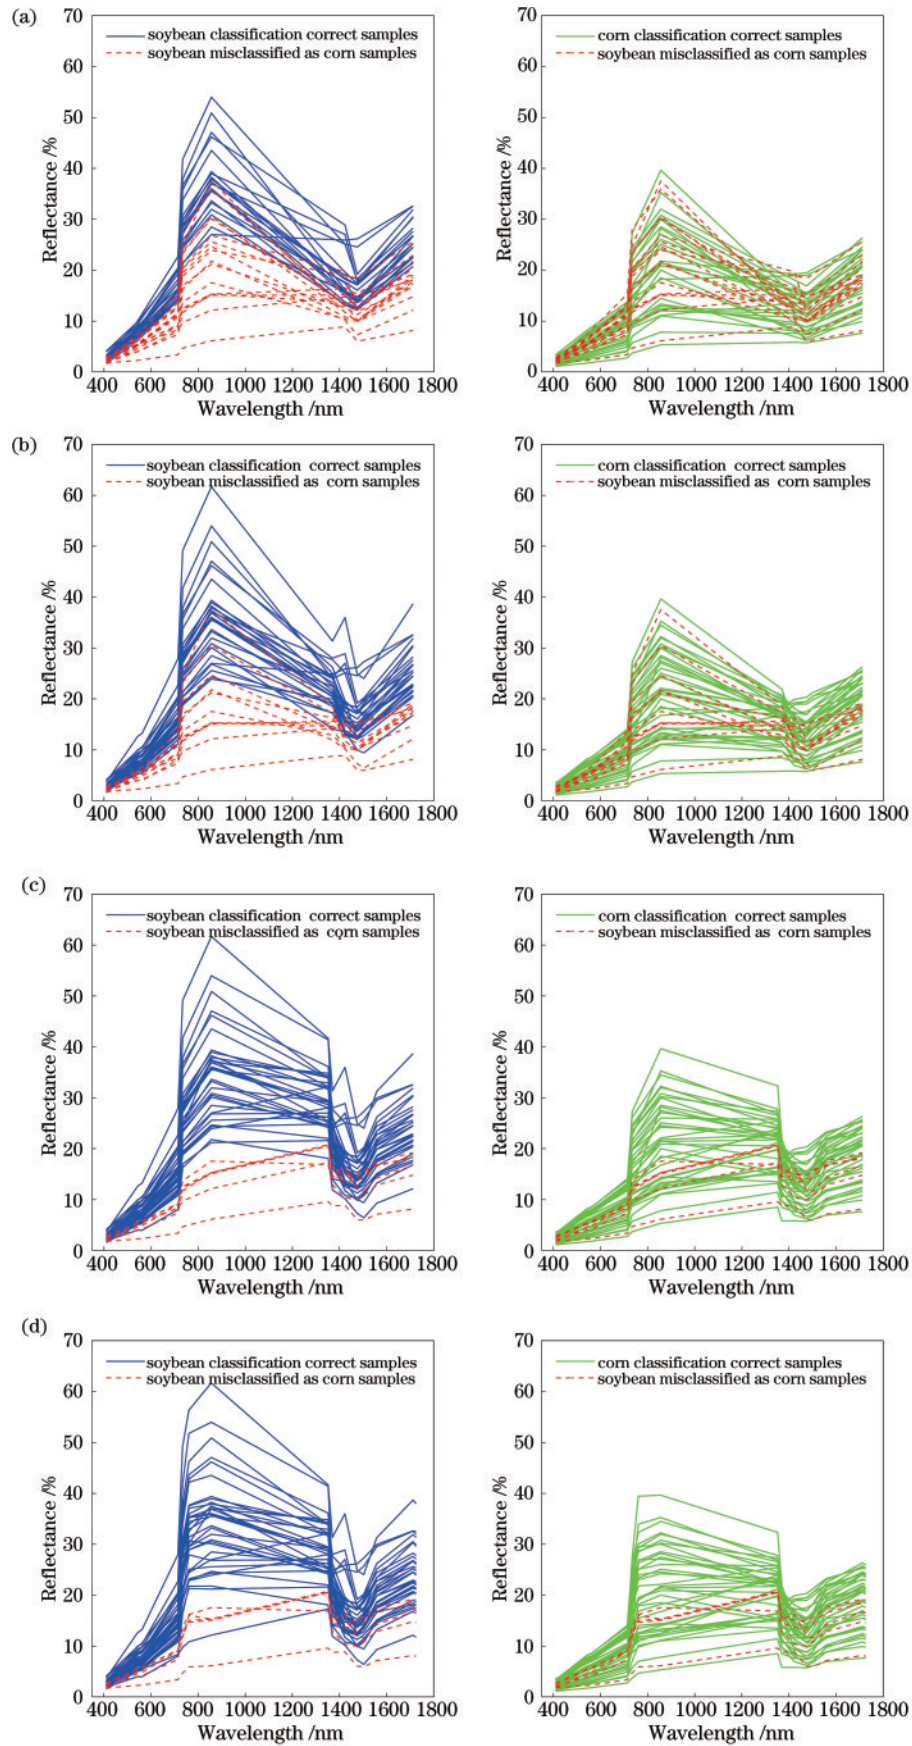


图 18 BP 不同阶段大豆错分为玉米样本与大豆、玉米分类正确样本对比。(a)第 1 阶段(16 个);(b)第 2 阶段(11 个);
(c)第 3 阶段(6 个);(d)第 4 阶段(5 个)

Fig. 18 Comparison of soybean misclassification into corn samples at different stages of BP with correct soybean and corn classification samples.(a) Stage 1(16); (b) stage 2(11); (c) stage 3(6); (d) stage 4(5)

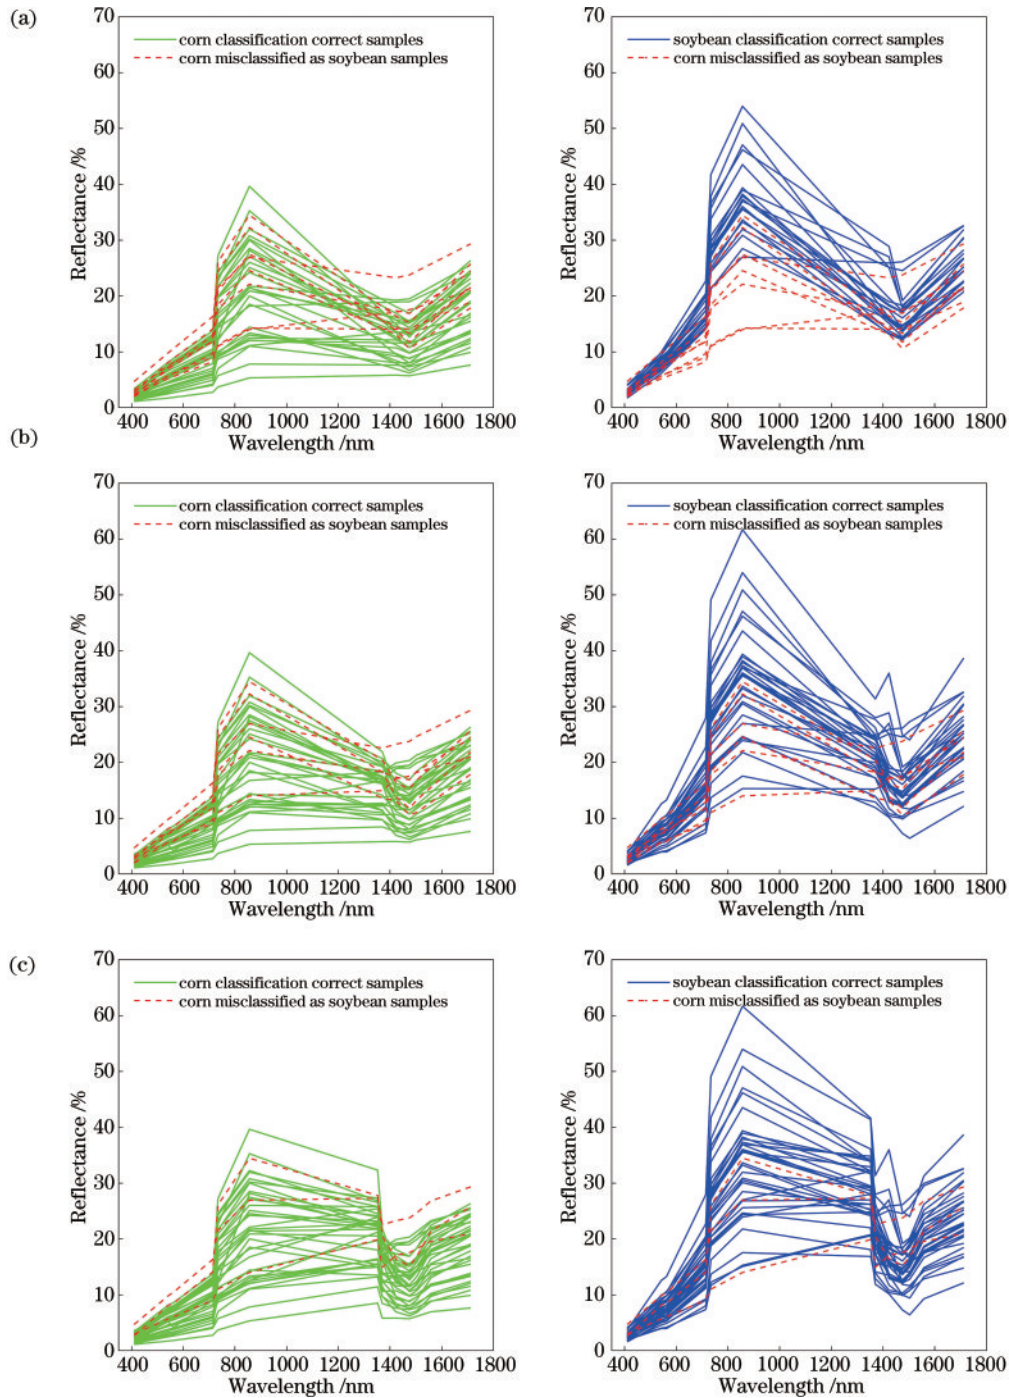


图 19 KNN 不同阶段玉米错分为大豆样本与玉米、大豆分类正确样本对比 (第 4 阶段无变化)。(a)第 1 阶段(8 个); (b)第 2 阶段(6 个); (c)第 3 阶段(3 个)

Fig. 19 Comparison of corn misclassification into soybean samples at different stages of KNN with correct corn and soybean classification samples(No change in the fourth stage).(a) Stage 1(8); (b) stage 2(6); (c) stage 3(3)

1352 nm 波段处有明显峰值的样本逐渐分类正确。

不同方法在不同阶段特征波段集合下的大豆、玉米总体分类精度,如图 20 所示。由图 20 可知,进阶式波段筛选方法对不同分类识别方法有不同的效果,每一阶段新增加的波段能够带来新的信息,对提高传统方法的总体分类精度有较大意义。在第 2 阶段和第 3

阶段特征波段筛选后,2 个传统方法的大豆、玉米总体分类精度显著提升,在第 4 阶段特征波段筛选之后,只有小幅度提升,因此,不再进行更深一层的特征波段筛选,并且在经过多个阶段的波段筛选之后,2 个传统方法的大豆、玉米总体分类精度逐渐接近于深度学习方法。

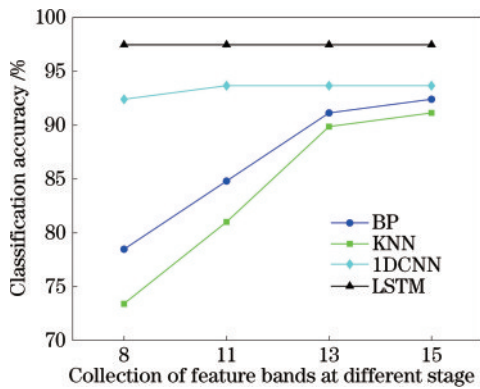


图 20 不同阶段特征波段集合下 4 种方法大豆和玉米的总体分类精度

Fig. 20 Overall classification accuracy of soybean and corn for four methods under different stage feature band sets

4 结 论

基于高光谱数据的典型地物分类识别方法进行了研究,采用基础波段筛选和进阶式波段筛选方法来挖掘隐藏在光谱数据中的诊断性光谱特征,并将 1DCNN 和 LSTM 两种深度学习方法与传统的 BP、KNN 算法进行对比分析与验证。研究表明:SPA 筛选出的特征波段能够有效代表 4 类地物的光谱特征,当特征波段不完整时,模型精度会严重降低,在与深度学习方法相结合时,可以在分类精度无较大损失的情况下,剔除光谱数据中大量的冗余信息,简化网络结构,提高模型效率;进阶式波段筛选方法在基础变量组合条件下,通过对错分样本的规律分析进行波段的筛选与增补,进阶式地引入针对错分样本的有效光谱信息,对提高传统方法的分类精度具有较大意义;在不经过光谱变换等预处理步骤时,1DCNN 和 LSTM 两种深度学习方法也能取得较高的分类精度,均超过 95%,明显优于 BP 和 KNN 两种传统方法,但训练过程较为复杂,可解释性较差。

参 考 文 献

- [1] 杜培军,夏俊士,薛朝辉,等. 高光谱遥感影像分类研究进展[J]. 遥感学报, 2016, 20(2): 236-256.
Du P J, Xia J S, Xue Z H, et al. Review of hyperspectral remote sensing image classification[J]. Journal of Remote Sensing, 2016, 20(2): 236-256.
- [2] 李瑞平. 高光谱林业遥感分类研究进展[J]. 安徽农业科学, 2014, 42(9): 2801-2805.
Li R P. Research progress analysis of hyperspectral remote sensing classification in forestry[J]. Journal of Anhui Agricultural Sciences, 2014, 42(9): 2801-2805.
- [3] 史飞飞,高小红,杨灵玉,等. 基于 HJ-1A 高光谱遥感数据的湟水流域典型农作物分类研究[J]. 遥感技术与应用, 2017, 32(2): 206-217.
Shi F F, Gao X H, Yang L Y, et al. Research on typical crop classification based on HJ-1A hyperspectral data in

- the Huangshui River Basin[J]. Remote Sensing Technology and Application, 2017, 32(2): 206-217.
- [4] 钱佳,郭云开,章琼,等. 矿区土壤重金属 Pb、Cd 污染状况高光谱分类建模[J]. 测绘通报, 2019(9): 82-84, 89.
Qian J, Guo Y K, Zhang Q, et al. Pollution classification of heavy metals Pb and Cd in mining area based on hyperspectral[J]. Bulletin of Surveying and Mapping, 2019(9): 82-84, 89.
- [5] 王延仓,章学深,李会民. 基于实测高光谱数据的树种分类[J]. 北华航天工业学院学报, 2021, 31(3): 4-7, 16.
Wang Y C, Zhang X S, Li H M. Tree species classification based on measured hyperspectral data[J]. Journal of North China Institute of Aerospace Engineering, 2021, 31(3): 4-7, 16.
- [6] 喻俊,李晓敏,张权,等. 基于实测高光谱数据的太湖湖滨带典型植被分类[J]. 江苏农业科学, 2017, 45(5): 240-244.
Yu J, Li X M, Zhang Q, et al. Classification of typical vegetation in Taihu Lake lakeside based on measured hyperspectral data[J]. Jiangsu Agricultural Sciences, 2017, 45(5): 240-244.
- [7] 李瑞平,黄侃,黄华国. 吉林蛟河主要树种叶片光谱分类[J]. 东北林业大学学报, 2015, 43(3): 48-55.
Li R P, Huang K, Huang H G. Leaf classification of main tree species in Jiaohe of Jilin with hyperspectral data [J]. Journal of Northeast Forestry University, 2015, 43(3): 48-55.
- [8] Mollot L A, Munro D, Bilby R E. Classifying fine-scale spatial structure of riparian forests using hyperspectral high-resolution remotely sensed imagery at the Cedar River municipal watershed in western Washington, USA [J]. Canadian Journal of Remote Sensing, 2007, 33(2): 99-108.
- [9] Mirik M, Ansley R J, Steddom K, et al. Remote distinction of A noxious weed (musk thistle: CarduusNutans) using airborne hyperspectral imagery and the support vector machine classifier[J]. Remote Sensing, 2013, 5(2): 612-630.
- [10] Mansour K, Mutanga O, Everson T, et al. Discriminating indicator grass species for rangeland degradation assessment using hyperspectral data resampled to AISA Eagle resolution[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2012, 70: 56-65.
- [11] Banskota A, Wynne R H, Kayastha N. Improving within-genus tree species discrimination using the discrete wavelet transform applied to airborne hyperspectral data [J]. International Journal of Remote Sensing, 2011, 32(13): 3551-3563.
- [12] Pu R L. Broadleaf species recognition with *in situ* hyperspectral data[J]. International Journal of Remote Sensing, 2009, 30(11): 2759-2779.
- [13] 曾帅,况润元,肖阳,等. 鄱阳湖湿地植物实测高光谱数据分类[J]. 遥感信息, 2017, 32(5): 75-81.
Zeng S, Kuang R Y, Xiao Y, et al. Measured hyperspectral data classification of Poyang Lake wetland vegetation[J]. Remote Sensing Information, 2017, 32(5): 75-81.

- [14] Meza Ramirez C A, Greenop M, Ashton L, et al. Applications of machine learning in spectroscopy[J]. Applied Spectroscopy Reviews, 2021, 56(8/9/10): 733-763.
- [15] 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 Q X, Wang Q H, Ma M H, et al. Non-destructive detection of male and female information of early duck embryos based on visible/near infrared spectroscopy and deep learning[J]. Spectroscopy and Spectral Analysis, 2021, 41(6): 1800-1805.
- [16] 鲁梦瑶, 杨凯, 宋鹏飞, 等. 基于卷积神经网络的烟叶近红外光谱分类建模方法研究[J]. 光谱学与光谱分析, 2018, 38(12): 3724-3728.
Lu M Y, Yang K, Song P F, et al. The study of classification modeling method for near infrared spectroscopy of tobacco leaves based on convolution neural network[J]. Spectroscopy and Spectral Analysis, 2018, 38(12): 3724-3728.
- [17] Le B T. Application of deep learning and near infrared spectroscopy in cereal analysis[J]. Vibrational Spectroscopy, 2020, 106: 103009.
- [18] 国强, 彭龙. 基于三维卷积神经网络与超像素分割的高光谱分类[J]. 光学学报, 2021, 41(22): 2210001.
Guo Q, Peng L. Hyperspectral classification based on 3D convolutional neural network and super pixel segmentation [J]. Acta Optica Sinica, 2021, 41(22): 2210001.
- [19] 白鹤轩, 杨峰, 李丹阳, 等. 基于表面增强拉曼光谱的多组分物质分类识别[J]. 光学学报, 2021, 41(20): 2024001.
Bai H X, Yang F, Li D Y, et al. Multi-component substance classification and recognition based on surface-enhanced Raman spectroscopy[J]. Acta Optica Sinica, 2021, 41(20): 2024001.
- [20] 张祥东, 王腾军, 朱劭俊, 等. 基于扩张卷积注意力神经网络的高光谱图像分类[J]. 光学学报, 2021, 41(3): 0310001.
Zhang X D, Wang T J, Zhu S J, et al. Hyperspectral image classification based on dilated convolutional attention neural network[J]. Acta Optica Sinica, 2021, 41(3): 0310001.
- [21] LeBa Tuan, 肖冬, 毛亚纯, 等. 可见、近红外光谱和深度学习 CNN-ELM 算法的煤炭分类[J]. 光谱学与光谱分析, 2018, 38(7): 2107-2112.
Tuan L B, Xiao D, Mao Y C, et al. Coal classification based on visible, near-infrared spectroscopy and CNN-ELM algorithm[J]. Spectroscopy and Spectral Analysis, 2018, 38(7): 2107-2112.
- [22] 王璨, 武新慧, 李恋卿, 等. 卷积神经网络用于近红外光谱预测土壤含水率[J]. 光谱学与光谱分析, 2018, 38(1): 36-41.
Wang C, Wu X H, Li L Q, et al. Convolutional neural network application in prediction of soil moisture content [J]. Spectroscopy and Spectral Analysis, 2018, 38(1): 36-41.
- [23] Rong D, Wang H Y, Ying Y B, et al. Peach variety detection using VIS-NIR spectroscopy and deep learning [J]. Computers and Electronics in Agriculture, 2020, 175: 105553.
- [24] 何勇, 刘飞, 李晓丽. 光谱及成像技术在农业中的应用 [M]. 北京: 科学出版社, 2016: 130.
He Y, Liu F, Li X L. Application of spectral imaging technology in agriculture[M]. Beijing: Science Press, 2016: 130.