

DOI:10.16136/j.joel.2023.03.0224

# 基于邻域聚合与深度学习的小样本荒漠草原物种分类

张 涛, 杜建民\*, 毕玉革, 朱相兵, 高新超

(内蒙古农业大学 机电工程学院, 内蒙古 呼和浩特 010018)

**摘要:**随着气候变化和人类活动的影响,内蒙古草原逐渐荒漠化。为了解决传统地面调查的局限性,以及高光谱数据小样本分类难的问题。本文利用无人机(unmanned aerial vehicle, UAV)高光谱遥感技术对荒漠草原物种进行数据采集,并提出一种邻域聚合算法结合深度学习的小样本分类方法。首先,通过遗传算法(genetic algorithm, GA)与最佳指数因子(optimum index factor, OIF)对高光谱数据进行波段选择;其次,构建高光谱数据邻域特征,采用邻域聚合算法对其进行邻域特征融合;最后,采用多层感知机(multilayr perceptron, MLP)对融合后的特征进行分类。结果表明,邻域聚合算法在每类地物只有10个样本的情况下总体精度可达93.41%,Kappa系数为0.9120;并与SVM和多种深度学习模型对比,邻域聚合算法计算效率高、模型大小最小、分类精度最高。该方法的提出,满足草原物种识别要求,为草原生态系统的动态监测提供新方法。

**关键词:**荒漠草原; 物种分类; 邻域聚合; 小样本; 无人机(UAV); 高光谱遥感**中图分类号:**TP79   **文献标识码:**A   **文章编号:**1005-0086(2023)03-0291-08

## Classification of small sample desert grassland species based on neighborhood aggregation and deep learning

ZHANG Tao, DU Jianmin\*, BI Yuge, ZHU Xiangbing, GAO Xinchao

(College of Mechanical and Electrical Engineering, Inner Mongolia Agricultural University, Hohhot 010018, Inner Mongolia, China)

**Abstract:**With the influence of climate change and human activities, the grasslands in Inner Mongolia are gradually desertifying. In order to solve the limitation of traditional ground survey and the problem of difficulty to classify small samples of hyperspectral data, in this paper, we use unmanned aerial vehicle (UAV) hyperspectral remote sensing technology to collect data on desert grassland species and propose a small sample classification method with a neighborhood aggregation algorithm combined with deep learning. Firstly, the band selection of hyperspectral data is performed by a genetic algorithm (GA) with the optimum index factor (OIF). Secondly, the neighborhood features of hyperspectral data are constructed, and the neighborhood aggregation algorithm is used to fuse the neighborhood features. Finally, the fused features are classified by a multilayer perceptron (MLP). The results show that the overall accuracy of the neighborhood aggregation algorithm can reach 93.41% with only 10 samples per class of features, and the Kappa coefficient is 0.9120; compared with SVM and various deep learning models, the neighborhood aggregation algorithm has high computational efficiency, the smallest model size, and the highest classification accuracy. The proposed method meets the requirements of grassland species identification and provides a new method for the dynamic monitoring of grassland ecosystems.

**Key words:** desert steppe; species classification; neighborhood aggregation; small sample; unmanned aerial vehicle (UAV); hyperspectral remote sensing

\* E-mail:nndjwc202@imau.edu.cn

收稿日期:2022-04-01 修订日期:2022-06-02

基金项目:国家自然科学基金(31660137)资助项目

## 0 引言

草原生态环境是我国重要的生态屏障<sup>[1]</sup>。内蒙古草原作为全国草原总面积之首,草原面积占全区面积的73.4%,是国家重要的畜牧业生产基地,同时在保护生物多样性和防风固沙等方面有着不可替代的作用。然而,由于人类活动和气候变化等原因,草原荒漠化问题日渐突出。草原荒漠化不仅加剧原本的荒漠化进程,还会降低草原生产力,减少草原物种多样性,严重威胁着我国北方草原的生态平衡<sup>[2]</sup>。因此,亟需一种高效、准确的技术和方法对荒漠草原进行有效的监测,为荒漠草原的恢复治理提供帮助。

遥感技术是我国热门的研究领域,在农业和环境等领域均有应用<sup>[3, 4]</sup>。卫星遥感也常用于草地覆盖度的估算,但因其空间分辨率的限制,无法满足草原的物种分类要求<sup>[5]</sup>。高光谱图像的波段数量可达上百个,高光谱分辨率高,特征信息丰富,在草原物种分类方面具有潜力。基于地面高光谱遥感技术因其较高的空间分辨率,能准确分类出草原物种,但监测范围小,无法揭示草原植被的空间分布。无人机(unmanned aerial vehicle, UAV)高光谱遥感能同时兼顾空间分辨率和监测范围,在保证分类精度的同时提升监测效率,对于草原植被物种的分类具有优势。

目前,高光谱图像的分类方法主要有机器学习和深度学习两种分类算法<sup>[6, 7]</sup>。通常,对于机器学习算法,主要通过对图像进行特征分析提取,并将提取出的像元特征用于分类,在分类性能上表现不错。例如,杨红艳<sup>[8]</sup>等采用随机森林算法对荒漠草原植被进行分类,其总体分类精度可达91.06%。但是,机器学习在对高光谱图像进行分类之前需要进行大量的特征分析和提取,工作量巨大。对于深度学习算法,主要通过滑动窗口对像元进行采样,并将其传入卷积神经网络进行分类。例如,刘浩<sup>[9]</sup>等利用A-Clenet5深度学习模型对草原草种进行分类,其总体分类精度可达92.18%。PI<sup>[10]</sup>等利用3DCNN模型对草原的3个植被群落进行分类,其总体分类精度为92.62%。但是,现阶段的深度学习模型大小过大,不易于在移动端进行部署,同时要求具有更多的训练样本数量。

针对上述问题,本文采用UAV高光谱遥感技术对内蒙古地区的格根塔拉草原的植被物种进行数据采集,并提出一种邻域聚合算法结合深度学习的荒漠草原小样本数据的物种分类模型。本文旨在讨论小样本数据的荒漠草原物种分类,以

期为荒漠草原生态系统的动态监测提供理论基础。

## 1 数据采集与预处理

### 1.1 数据采集

#### 1.1.1 研究区域

本研究区域处于内蒙古自治区格根塔拉草原,地理坐标为东经111°52'48"、北纬41°46'48",如图1所示。该区域年均气温在3.5℃,年降水量约为260 mm,海拔高度约为1456 m,属于中温带大陆性气候<sup>[11]</sup>。研究区草地类型属于短花针茅荒漠草原,表层植被稀疏、低矮。该研究区域植被群落可分为建群种、优势种和伴生种,其中建群种为短花针茅,优势种为无芒隐子草和冷蒿,伴生种为椭圆蒿、羊草和驼绒藜等。

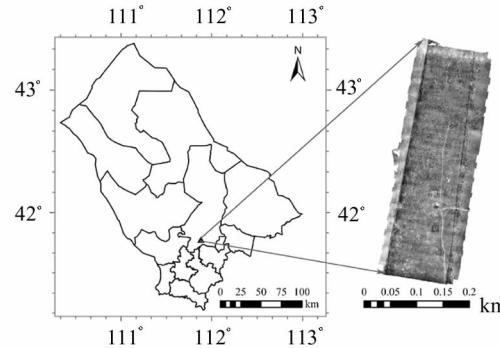


图1 研究区域与无人机航拍图

Fig.1 Study area and UAV aerial photography

#### 1.1.2 实验器材

本研究所用仪器主要有高光谱仪、UAV与云台等。其中,高光谱仪采用双利合谱研制的GaiaSky-mini型高光谱仪,扫描速度为60 line/s。采集过程中,设置采集波段数为256个波段,波长范围设置为400—1000 nm,光谱分辨率为3.5 nm。UAV采用大疆M600 Pro,空机质量9.5 kg,最大载荷为6 kg,满载时可持续飞行16 min。云台采用大疆如影MX。

#### 1.1.3 数据采集

根据研究区域植被长势情况,数据采集时间为2021年7月份。采集时间为中午10:00—14:00之间。为确保所采集数据的一致性,采集条件需满足风力小于3级、天气晴朗、无云雾遮挡、自然光下采集。研究区域采集总面积为 $2.5 \times 10^4$  m<sup>2</sup>,样区内每类地物放置10个样方。其中,纯净样方主要采集短花针茅、无芒隐子草、冷蒿和驼绒藜,共计40个,混合样方10个。样方尺寸大小设置为1 m × 1 m,并在样方附近采用小旗和地垫进行标记。

同时,记录每个样方内植被物种的类型、覆盖度等,并记录样方中心处的经纬度坐标以便后期定位。

经过多次测试,在保证采集效率与精度的同时,设置 UAV 飞行高度为 20 m,并设置采集的单幅高光谱图像尺寸为 696 samples  $\times$  775 lines  $\times$  256 bands,空间分辨率为 1.73 cm。采集前后均需要进行一次反射率校正,每个样方采集次数不少于 3 次。在采集过程中,使用大疆精灵 4 Pro UAV 对研究区域进行按航线飞行拍摄,并绘制研究区域的数字正射影像图。

## 1.2 数据预处理

### 1.2.1 数据预处理与分析

采集后的高光谱影像由于外在因素的影响,会引起图像的扭曲变形。通过人工目视检查,对成像不佳的数据进行剔除。将剩余数据导入 Spec VIEW 软件中进行反射率校正。

根据大量的地面调查,利用 ArcGIS 10.7 和 ENVI 5.3 在采集的 UAV 高光谱图像中对样方内的物种进行选择和生成样本。考虑样本均衡性问题,每类地物样本选取按草地面积占比设置,共获得 3459 个样本,其中短花针茅 1365 个、无芒隐子草 401 个、冷蒿 811 个、驼绒藜 354 个、裸土 284 个,以及地垫、小旗、垃圾等其他地物 244 个。每类地物的光谱曲线如图 2 所示。

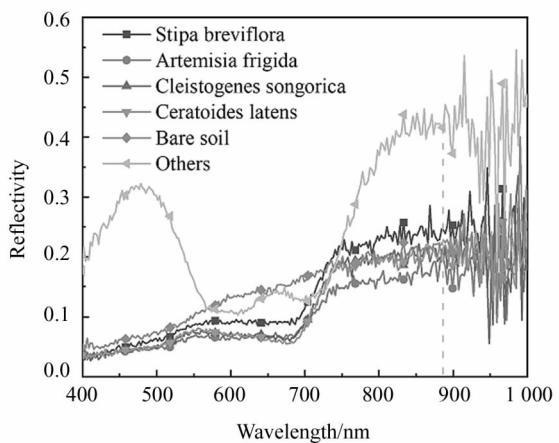


图 2 不同物种光谱曲线  
Fig. 2 Spectral curves of different species

从图 2 中可以看出,其他类地物(地垫、小旗和垃圾等)的光谱曲线与其余 5 种地物的光谱曲线差异最大。裸土的光谱曲线呈直线缓慢增加,在 550—740 nm 之间与 4 类植被地物类型有较大差异。短花针茅的光谱曲线在 580 nm 之后与剩余 3 类植被地

物的光谱曲线呈现出一定的差异。无芒隐子草、冷蒿和驼绒藜 3 类地物的光谱曲线较为相似,其中无芒隐子草与驼绒藜的光谱曲线最为相似。在 740 nm 之后,相比于无芒隐子草和驼绒藜的光谱曲线,冷蒿的反射率值较低。此外,在 886.6 nm 之后,因噪声的影响,不同种类的地物光谱曲线均出现较大的波动,应给予去除。最后获得的波段数量为 205 个波段。

### 1.2.2 基于遗传算法的 OIF 波段选择

高光谱数据具有波段数多,特征信息丰富等特点。但是波段之间往往存在较大的相关性,使得数据存在大量的冗余特征,造成计算成本的增加。因此,有必要对高光谱图像的波段进行降维。

最佳指数因子(optimum index factor,OIF)是一种无监督的特征波段选择算法。该算法不仅能有效去除波段之间的相关性,还能兼顾各波段的信息量,能极大地保持原有数据的特征,在高光谱波段选择中得到广泛应用。OIF 值越大,则表明该组波段组合最好,其式如下:

$$R_{OIF} = \frac{\sum_{i=1}^n S_i}{\sum_{i=1}^n \sum_{j \neq i}^n |R_{ij}|}, \quad (1)$$

式中,  $R_{OIF}$  为 OIF,  $S_i$  为第  $i$  个波段的标准差,  $R_{ij}$  为第  $i$  个波段与第  $j$  个波段之间的相关系数。

遗传算法(genetic algorithm,GA)是根据自然界中生物进化规律设计提出的一种搜索最优解的算法,主要包括选择、交叉和变异 3 个基本算子。该算法过程简单、收敛性强,能有效求解出全局最优解。因此,本研究通过采用 GA 对 OIF 进行优化求解。

在 GA 中,设置种群大小为 25,两点交叉概率为 0.6,变异概率设置为 0.1,基因大小设置为 205,迭代次数为 100 次。对于 OIF 波段选择算法,在相同 OIF 值的情况下,选取波段数量最少的组合方式。图 3 为不同迭代次数的 OIF 值和波段数量。从图中可以看出,随着迭代次数的增加,OIF 值不断增大。当迭代次数到达 28 次的时候,OIF 值在很长一段时间内不再变化,直到迭代次数到达 96 次时,OIF 值又开始增长,并又趋于稳定。当 OIF 值到达最大时,波段组合的数量最少为 101 个波段,因此选取该组波段组合用于后期数据的分析。

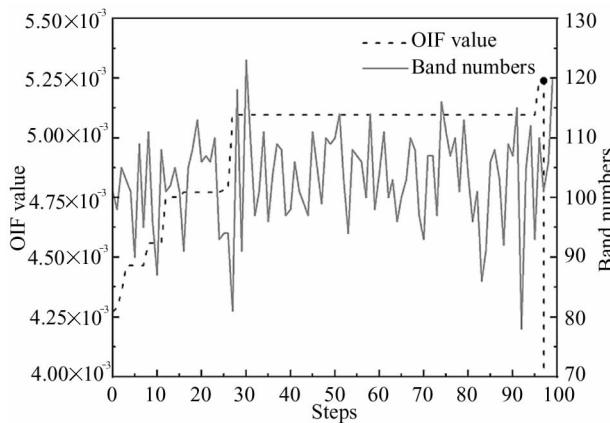


图 3 不同迭代次数的 OIF 值和波段数量

Fig. 3 OIF values and band numbers for different number of iterations

## 2 邻域聚合算法与深度学习模型构建

### 2.1 邻域聚合算法原理

目前,高光谱图像的分类主要是通过提取图像的像元纹理特征进行分类的机器学习算法,还有采用滑动窗口提取特征进行分类的卷积神经网络算法。上述两种算法在特征提取过程中会增加非目标地物的特征信息,将过多的背景信息带入特征分类中,不利于目标地物的分类研究。针对此类问题,本文提出一种邻域聚合算法对高光谱图像进行分类。

邻域聚合算法主要分为邻域特征提取和邻域特征聚合两个部分。对于邻域特征提取,主要通过滑动窗口对高光谱图像进行逐个像元采样,同时计算单个窗口内中心像元与邻域像元之间的相关性,并按照相关性大小保留相关性最大的前  $k$  个像元,将剩余像元剔除。对于邻域像元的相关性计算,本文采用欧氏距离计算。在  $n$  维空间两点之间的欧氏距离计算式如下:

$$d(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (2)$$

式中,  $d$  表示两点之间的欧氏距离,  $X, Y$  表示  $N$  维空间向量。

单个窗口邻域像元特征提取过程可由图 4 表示。图中“★”表示中心像元,“√”、“×”分别表示通过邻域特征提取之后所保留的像元与剔除的像元。

对于邻域特征聚合的聚合函数可有以下定义。假设输入的是一个 3D 张量  $\mathbf{X}_i \in \mathcal{R}^{C \times n \times m}$ , 其中  $C$  是通道数,  $n$  和  $m$  是输入数据的高和宽。此处,  $n=m$  是一个奇数,为滑动窗口的尺寸大小。通过邻域特征提取后(假设取前  $k$  个邻近像元保留),此时输入的 3D 张量变为  $\mathbf{x}_i \in \mathcal{R}^{C \times k}$ 。之后将对提取出的特征进行

聚合,单层聚合函数式如下:

$$\mathbf{y}_l = \mathbf{W}_l \mathbf{x}_l^T + \mathbf{b}_l, \quad (3)$$

式中,  $\mathbf{y}_l \in \mathcal{R}^{s \times C}$  是第  $l$  层聚合后的特征输出,  $\mathbf{W}_l \in \mathcal{R}^{s \times k}$  和  $\mathbf{b}_l \in \mathcal{R}^{s \times C}$  是可学习参数。其中,  $s$  是第  $l$  层的聚合次数,属于超参数。

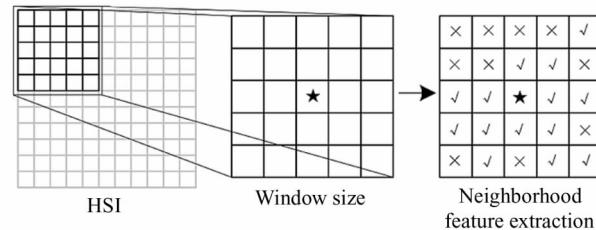


图 4 邻域特征提取示意图

Fig. 4 Schematic of neighborhood feature extraction

### 2.2 深度学习模型构建

本研究构建两层邻域聚合函数,在对提取的特征进行聚合之后,将聚合结果输入至多层感知机(multilayer perceptron, MLP)进行最后的分类,图 5 为模型结构。两层邻域聚合次数分别设置为 128 和 1, MLP 设置为单层隐藏层,层数为 101, 最后输出 6 个类别的标签。此外,在每一层邻域聚合之后,采用 ReLU 函数进行非线性激活。同时,在模型开始训练之前,将模型的  $\mathbf{W}$  初始化为高斯分布,  $\mathbf{b}$  初始化为 0。

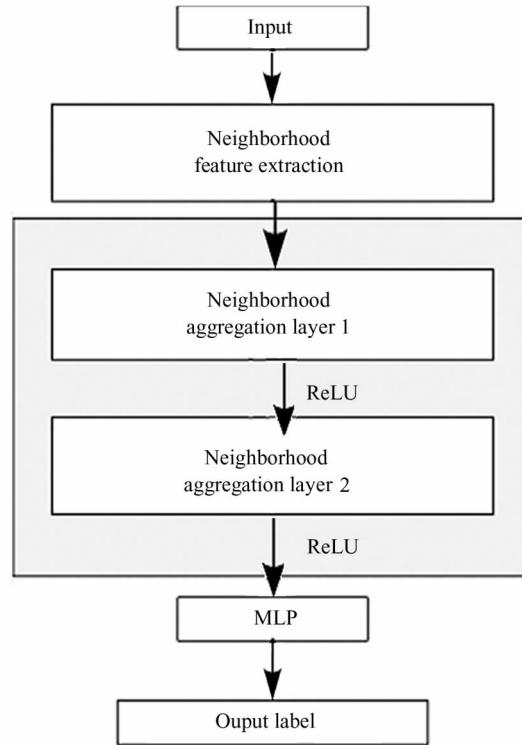


图 5 邻域聚合算法模型结构

Fig. 5 Neighborhood aggregation algorithm model structure

具体算法流程如下:

步骤1 根据式(2)计算滑动窗口内中心像元与邻域像元之间的相关性。按照相关性大小,取前 $k$ 个相关性最大的数据进行保留。

步骤2 根据式(3)对步骤1所提取的数据进行两层特征聚合。聚合后的输出为 $\mathbf{y}_o \in \mathcal{R}^{1 \times C}$ 。

步骤3 通过MLP对聚合结果进行分类。同时,计算出分类损失值,采用反向传播算法对模型的各个参数进行优化。

### 3 实验结果与分析

本实验基于Pytorch-GPU深度学习框架,采用python语言编程。模型训练的学习率为0.001,迭代次数为500次,损失优化函数采用Adam算法,损失函数采用交叉熵损失函数,batch size为128,滑动窗口尺寸为9, $k$ 值为30。计算机硬件配置为:i7-11800 H CPU、GeForce RTX 3060 GPU、内存16 GB。在训练过程中,每迭代5次记录测试集的损失和准确率。模型分类性能评价指标选取总体精度(overall accuracy, OA)和Kappa系数。随机选取每类地物的10个样本作为训练集,划分训练集与测试集的数量如表1所示。

表1 训练集与测试集样本数量

Tab. 1 Number of training set and test set samples

No.	Class	Training	Test
1	Stipa breviflora	10	1 355
2	Artemisia frigida	10	801
3	Cleistogenes songorica	10	391
4	Ceratoides latens	10	344
5	Bare soil	10	274
6	Others	10	234
	Total	60	3 399

#### 3.1 实验参数分析

##### 3.1.1 滑动窗口尺寸分析

滑动窗口的尺寸大小是对像元周围邻域采样面积的大小。在采样过程中,滑动窗口尺寸越大,所包含的地物信息越多,邻域特征提取的信息也更为丰富。但滑动窗口尺寸也不宜过大,尺寸过大不仅不会增加模型的分类精度,还会增加模型的计算成本。图6为不同滑动窗口尺寸的OA值和训练时间。从图6中可看出,随着滑动窗口尺寸增加,模型所消耗的训练时间也逐渐增大,OA值呈现出先增后减的趋势。当滑动窗口尺寸为11时,模型分类精度最高,时间成本适中。因此,选择滑动窗口的尺寸大小

为11。

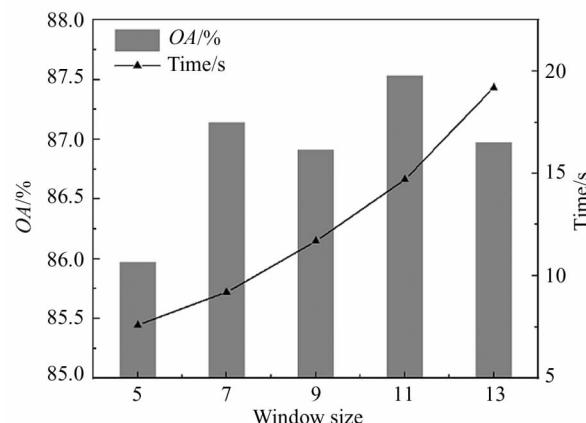


图6 不同窗口尺寸的分类性能对比

Fig. 6 Comparison of classification performance of different window sizes

##### 3.1.2 $k$ 值分析

$k$ 值是邻域特征提取中所保留像元的数量。在实验过程中,如果 $k$ 值太小,则无法提取更为丰富的邻域信息进行分类;如果 $k$ 值太大,则会提取过多的背景信息,影响邻域聚合效果,从而降低模型分类性能。图7为不同 $k$ 值的OA值和训练时间。从图7中可以看出,随着 $k$ 值的增加,模型所消耗的训练时间逐渐增大,OA值呈现出先增后减的现象。当 $k$ 取值为30时,模型分类精度最高,时间成本适中。因此,选择 $k$ 的大小为30。

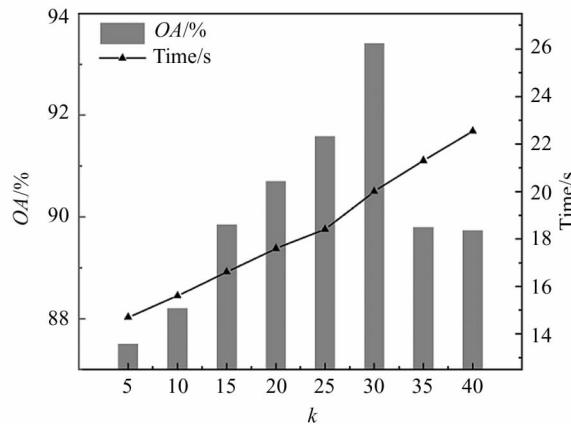


图7 不同 $k$ 值的分类性能对比

Fig. 7 Comparison of classification performance for different  $k$  values

#### 3.2 消融实验分析

为评估本文所提出的算法中每个模块的有效性,将进行消融实验。对于基准模型,不采用任何数据预处理与模型参数初始化,将数据直接进行全邻

域聚合。表2展示了不同模块组合的OA值和模型消耗的训练时间成本。从表2中得出,在不经过任何数据预处理的实验a精度最低,并且所消耗的时间成本最高。经过数据预处理之后的实验b精度得到28.81%的提升,并且模型训练的时间成本降低了64%。对于加入参数初始化之后的实验c,在相同的训练时间内,模型的分类精度提升了1.06%。而对

于本文所提出的邻域聚合算法(实验e),分类精度最高,为93.41%,其模型所消耗的训练时间成本也最低,仅为20 s。此外,为进一步评估本文算法的分类性能,将数据不经过任何预处理直接进行邻域聚合的实验d中,分类性能可达92.23%,远高于a、b、c 3组实验,表明邻域聚合算法在不经过预处理的情况下也具有一定的优势,从而进一步说明了所提算法

表2 不同模块组合的模型分类性能对比

Tab. 2 Comparison of model classification performance for different module combinations

No.	Baseline	Data preparation	Parameter initialization	Neighborhood feature extraction	OA / %	Time/s
a	✓				59.60	129
b	✓	✓			88.41	47
c	✓	✓	✓		89.47	47
d	✓		✓	✓	92.23	43
e	✓	✓	✓	✓	93.41	20

的有效性。

### 3.3 模型对比实验分析

为验证本文所提出方法的有效性,将选取SVM<sup>[12]</sup>、MLP<sup>[13]</sup>、2DCNN<sup>[14]</sup>、3DCNN<sup>[15]</sup>、Resnet18<sup>[16]</sup>、Densenet121<sup>[17]</sup>共6种分类模型进行对比实验。此外,再选取一个最新的小样本分类模型(SFE-3DCNN)<sup>[18]</sup>进行对比实验,以验证本文所提方法的分类性能。同时,为确保公平性,所有实验均采用相同的预处理方法,并且在同一个实验环境下进行。此外,所选用的对比模型参数均与原论文相同。实验中,随机选取每类地物的10个样本作为训练集。

#### 3.3.1 模型分类性能的对比

不同模型的分类OA如表3所示,表中黑体加粗代表所有对比算法中分类精度最高。从表3中可以看出,SVM分类算法的总体分类精度最差,表明深度学习具有优于传统的机器学习的特征提取能力。

对于MLP、2DCNN和3DCNN的分类算法,2DCNN和3DCNN的分类算法明显优于只有全连接层的MLP分类算法,表明卷积结构能更好地提取高光谱图像的特征。对于Resnet18分类算法,其总体分类精度明显高于SVM、MLP、2DCNN和3DCNN等分类算法,表明具有残差结构的网络模型具有更好的特征提取能力。而具有密集连接的Densenet121分类算法,其分类性能更是优于Resnet18,表明密集连接在能加强特征重用,有效提升模型的分类性能。具有小样本分类性能SFE-3DCNN分类算法具有远超Resnet18和Densenet121等分类算法的分类性能,但是与本文所提分类算法相比,总体分类性能仍然欠佳。

相比而言,本文所提出的邻域聚合算法在所有对比模型中总体分类性能最好,其OA值可达93.41%,Kappa系数可达0.9120,表明了邻域融合算法在小样本情况下分类性能的有效性。

表3 不同模型分类总体精度  
Tab. 3 Overall accuracy of different models classification

No.	SVM	MLP	2DCNN	3DCNN	Resnet18	Densenet121	SFE-3DCNN	This paper
1	47.08	57.71	67.97	66.86	77.05	91.96	<b>96.31</b>	95.54
2	94.88	81.02	79.15	86.27	91.26	82.15	<b>99.25</b>	95.76
3	31.71	76.98	83.12	68.54	<b>92.33</b>	79.54	70.08	78.52
4	67.15	84.88	85.47	93.60	85.76	89.53	90.41	<b>95.64</b>
5	74.45	100.00	100.00	100.00	96.72	100.00	100.00	<b>100.00</b>
6	65.38	48.29	68.38	64.53	72.22	55.56	57.69	<b>87.61</b>
OA / %	62.08	70.93	76.73	76.85	84.29	86.11	91.03	<b>93.41</b>
Kappa	0.5169	0.6314	0.7023	0.7050	0.7974	0.8170	0.8798	<b>0.9120</b>

### 3.3.2 模型计算效率与模型参数的对比

为更进一步讨论邻域聚合算法的计算效率与模型参数大小等,选择相同的对比模型进行实验分析,见表4。从表4中可以看出,SVM具有较少的超参数,因此模型所消耗的时间成本最低,但其分类性能较差。本文所提出的邻域聚合算法除MLP外,在所有深度学习对比模型中,所消耗的时间成本最低。同时,对于模型的参数量与模型大小,在所有对比模型当中最小,更易于移动端的部署。表明邻域聚合算法在保证分类精度的同时,不仅具有更高的计算效率,在模型大小方面也更具优势,更有利移动设备的部署。

表4 不同模型计算效率和模型参数

Tab. 4 Computational efficiency and model parameters of different models

Model	Parameters size/MB	Model size /MB	Time /s
SVM	/	/	0.03
MLP	11.99	11.9	15.25
2DCNN	1.20	1.12	20.15
3DCNN	6.57	0.52	49.37
Resnet18	44.12	43.9	110.16
Densenet121	35.51	27.3	145.39
SFE-3DCNN	1.11	1.13	189.81
This paper	0.15	0.02	20.06

### 3.4 基于邻域聚合算法的样区分类可视化

图8展示了基于邻域聚合算法的3个样区分类可视化图。通过人工实地调查记录和UAV航拍RGB镶嵌图像的对比,3个样区的分类结果与实际

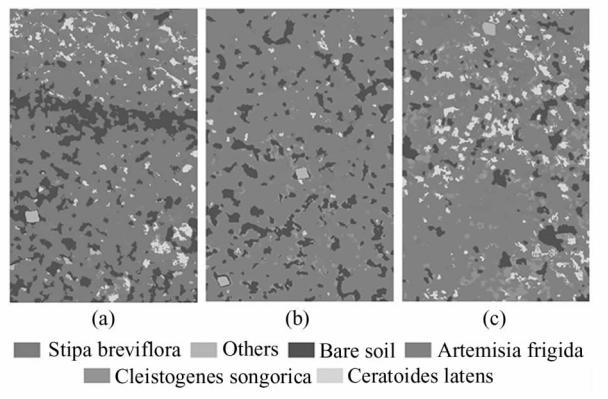


图8 样区分类可视化:(a) 短花针茅样区;  
(b) 冷蒿样区;(c) 混合样区

Fig. 8 Visualization of sample area classification:  
(a) Stipa breviflora sample region;  
(b) Artemisia frigida sample region; (c) Mixed sample area

地物的空间分布相符,具有较好的分类效果;不同地物之间能进行有效的区分,很好地保留了地物的空间特征。

## 4 结论

本研究通过构建低空UAV遥感平台进行了荒漠草原典型植被物种的数据采集,并建立了一种邻域聚合算法针对小样本高光谱数据的分类。同时,采用了GA结合OIF指数的波段选择,在保证分类精度的同时,提高了模型的计算效率。此外,讨论了模型不同参数对其分类性能的影响,确定了模型的最佳参数。与此同时,还与不同的分类算法进行了对比。结果表明,本文所提出的邻域聚合算法在所有对比模型中总体分类精度最高,其OA值为93.41%、Kappa系数为0.9120;在所有对比的深度学习算法中,计算效率高、模型参数量和模型大小最低。未来还需要更进一步探讨如何在更少的样本上提升模型的分类性能。

## 参考文献:

- [1] 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.
- [2] SHANG C, WU T, HUANG G, et al. Weak sustainability is not sustainable: Socioeconomic and environmental assessment of Inner Mongolia for the past three decades [J]. Resources, Conservation and Recycling, 2019, 141: 243-252.
- [3] CHEN S, GAO Y, FAN K, et al. Prediction of drought-induced components and evaluation of drought damage of tea plants based on hyperspectral imaging[J]. Frontiers in Plant Science, 2021, 12: 695102.
- [4] ACHARYA B S, BHANDARI M, BANDINI F, et al. Unmanned aerial vehicles in hydrology and water management: applications, challenges, and perspectives[J]. Water Resources Research, 2021, 57 (11): e2021WR029925.
- [5] LI K, WANG L, YIN D. Deriving corn and soybeans fractions with land remote-sensing satellite (system, land-sat) imagery by accounting for endmember variability on Google Earth Engine[J]. International Journal of Remote Sensing, 2021, 42(12): 4489-4509.
- [6] KONG Z, YANG H. Hyperspectral image classification method based on machine learning[C]//2021 IEEE International Conference on Computer Science, Electronic In-

- formation Engineering and Intelligent Control Technology (CEI), September 24-26, 2021, Fuzhou, China. New York: IEEE, 2021: 392-395.
- [7] LIU J, ZHANG K, WU S, et al. An investigation of a multi-dimensional CNN combined with an attention mechanism model to resolve small-sample problems in hyperspectral image classification [J]. Remote Sensing, 2022, 14(3): 785.
- [8] YANG H, DU J, RUAN P, et al. Vegetation classification of desert steppe based on unmanned aerial vehicle remote sensing and Random forest [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(6): 186-194.  
杨红艳, 杜健民, 阮培英, 等. 基于无人机遥感与随机森林的荒漠草原植被分类方法 [J]. 农业机械学报, 2021, 52(6): 186-194.
- [9] LIU H, DU J, PI W, et al. Identification and classification of desert grassland species based on A-Clenet5 [J]. Journal of Optoelectronics • Laser, 2019, 30(10): 1056-1061.  
刘浩, 杜建民, 皮伟强, 等. 基于 A-Clenet5 的荒漠化草原草种识别与分类 [J]. 光电子·激光, 2019, 30(10): 1056-1061.
- [10] PI W, DU J, BI Y, et al. 3D-CNN based UAV hyperspectral imagery for grassland degradation indicator ground object classification research [J]. Ecological Informatics, 2021, 62: 101278.
- [11] ZHANG T, DU J, ZHANG H, et al. Research on recognition method of desert steppe rat hole based on unmanned aerial vehicle hyperspectral [J]. Journal of Optoelectronics • Laser, 2022, 33(2): 120-126.  
张涛, 杜健民, 张海军, 等. 基于无人机高光谱荒漠草原鼠洞识别方法研究 [J]. 光电子·激光, 2022, 33(2): 120-126.
- [12] GHAMISI P, PLAZA J, CHEN, et al. Advanced spectral classifiers for hyperspectral images: a review [J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(1): 8-32.
- [13] PARSAIE A. Predictive modeling the side weir discharge coefficient using neural network [J]. Modeling Earth Systems and Environment, 2016, 2(2): 1-11.
- [14] YUE J, ZHAO W, MAO S, et al. Spectral-spatial classification of hyperspectral images using deep convolutional neural networks [J]. Remote Sensing Letters, 2015, 6(6): 468-477.
- [15] PI W, DU J, LIU H, et al. Desertification glassland classification and three-dimensional convolution neural network model for Identifying desert grassland landforms with unmanned aerial vehicle hyperspectral remote sensing images [J]. Journal of Applied Spectroscopy, 2020, 87(2): 309-318.
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [17] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 2261-2269.
- [18] LU Y, WANG L, SHI Y. Classification of hyperspectral images with small-sized samples based on spatial-spectral feature enhancement [J]. Journal of Harbin Engineering University, 2022, 43(3): 436-443.  
陆瑶, 王立国, 石瑶. 小样本下基于空谱特征增强的高光谱图像分类 [J]. 哈尔滨工程大学学报, 2022, 43(3): 436-443.

## 作者简介:

杜建民 (1960—), 男, 博士, 教授, 博士生导师, 主要从事环境测控技术与装备智能化方面的研究。