

基于高光谱和 LiDAR 的黄河口湿地植被分类方法

许明明¹, 刘航¹, 窦庆文², 刘善伟¹, 盛辉¹

(1 中国石油大学(华东)测绘系 青岛 266580;

2 山东省国土测绘院 济南 250102)

摘要: 利用无人机 (Unmanned Aerial Vehicle, UAV) 高光谱影像 (Hyper-spectral Imaging, HSI) 和激光雷达 (Light Detection and Ranging, LiDAR) 数据开展黄河口湿地植被分类方法研究。由于高空间分辨率 HSI 光谱变异性强, 以及 LiDAR 点云密度不均匀, 分类结果呈现出“椒盐”现象。为了解决这些问题, 本文提出了一种结合空谱特征融合和通道注意力机制的双分支卷积神经网络 (SSF-C-DBCNN)。光谱注意力机制通过为每个波段分配不同的权重来减少光谱变异性的影响。空间注意力机制侧重于学习和强调特征表达能力强的密集点云区域空间信息, 从而减轻 LiDAR 点云密度不均匀对结果的影响。最后, 在双分支融合特征后引入通道注意力机制来提取更深层次的特征。利用 UAV 采集的 HSI 和 LiDAR 数据进行实验验证, 结果表明, 本文提出方法的性能优于随机森林和五种深度学习方法, 分类结果更为贴合实际土地覆盖, 有效地抑制了“椒盐”现象。

关键词: 分类; 无人机高光谱; 激光雷达; 深度学习; 注意力机制

中图分类号: P237; TP75 文献标志码: A 文章编号: 2095-1000(2024)03-0102-12

DOI: 10.12347/j.ycyk.20240117001

引用格式: 许明明, 刘航, 窦庆文, 等. 基于高光谱和 LiDAR 的黄河口湿地植被分类方法[J]. 遥测遥控, 2024, 45(3): 102-113.

Classification Method of Wetland Vegetation in The Yellow River Delta Based on Hyperspectral and LiDAR

XU Mingming¹, LIU Hang¹, DOU Qingwen², LIU Shanwei¹, SHENG Hui¹

(1. Dept. Surveying and Mapping, China University of Petroleum (East China), Qingdao 266580, China;

2. Land Surveying and Mapping Institute of Shandong Province, Jinan 250102, China)

Abstract: By utilizing Unmanned Aerial Vehicle (UAV) Hyper-Spectral Imaging (HSI) and Light Detection and Ranging, this study aims to investigate the classification methods of wetland vegetation in the Yellow River estuary using LiDAR data. However, due to the high spatial resolution HSI spectral variability and uneven LiDAR point cloud density, the classification results exhibit a "pepper and salt" phenomenon. To address these issues, this paper proposes a two-branch convolutional neural network (SSF-C-DBCNN) that integrates empty spectrum feature fusion and channel attention mechanism. The spectral attention mechanism mitigates the impact of spectral variability by assigning different weights to each band. Meanwhile, the spatial attention mechanism focuses on learning and emphasizing dense point cloud regions with strong feature expression ability in order to alleviate the influence of uneven LiDAR point cloud density on the results. Finally, the channel attention mechanism is introduced for extracting deeper features after two-branch feature fusion. Experimental verification using HSI and LiDAR data collected by UAV demonstrates that the proposed method outperforms random forest as well as five deep learning methods, yielding more suitable classification results for actual land cover while effectively suppressing the "pepper and salt" phenomenon.

Keywords: Classification; UAV HSI; LiDAR; Deep learning; Attention mechanism

Citation: XU Mingming, LIU Hang, DOU Qingwen, et al. Classification Method of Wetland Vegetation in The Yellow River Delta Based on Hyperspectral and LiDAR[J]. Journal of Telemetry, Tracking and Command, 2024, 45(3): 102-113.

基金项目: 国家自然科学基金 (62071492); 山东省高等学校青创科技支持计划 (2023KJ068)

通信作者: 窦庆文 (358346367@qq.com)

收稿日期: 2024-01-17; 修回日期: 2024-02-23

0 引言

湿地是一种特殊且重要的生态系统,可以改善、调节生态环境,有着“地球之肾”的称号^[1]。湿地植被相对于一般植被来说,复杂程度更高,被普遍认为是一种可以直接反映整个湿地区域生态环境变化情况的重要敏感指示计^[2]。因此,有关湿地植被的研究常常被各界广泛关注,对湿地资源进行准确的识别和分类是利用和保护湿地资源、维持生态平衡的重要步骤。

湿地地区复杂程度高、通达性差,传统的人工野外调查方法需要耗费极大的人力和物力,而遥感技术具有观测范围广、监测周期短、受环境条件影响较小的优势^[3]。因此利用遥感手段对湿地地区进行准确、及时的监测,对于湿地生态系统的可持续管理和生物多样性保护具有重要意义。HSI具有大量的成像波段且有着较高的光谱分辨率,能够分辨出植被间的细小差异,提供丰富的植被水平结构信息^[4],已广泛应用于湿地分类。已有部分学者利用HSI对黄河口湿地植被进行分类研究,但这些研究多数基于单一的星载高光谱,如OHS^[5]、GF-5^[6]、HJ-1^[7]、ZY-1 02D^[8]、CHRIS^[9]等,以及UAV高光谱^[10],联合其他数据进行分类的研究目前较少。然而单一使用HSI进行分类,在面对光谱特征极为相似的不同植被时,常常出现严重的误分,特别是高空间分辨率HSI中,“同物异谱、同谱异物”现象更为严重,难以取得令人满意的分类效果。为了解决这个问题,提高分类精度,引入多源遥感数据是一种有效的策略^[11]。其中,LiDAR点云能够反映植被的三维结构信息尤其是垂直结构信息^[12],这种垂直结构上的高度差异可以作为一种额外的特征维度增加到光谱特征波段中,可以增加特征的维度,提供额外的信息,更全面地描述地物的特征,在特征空间中形成更丰富的表示,有效增加不同植被类型之间的差异信息,增强不同植被类型的区分度,使分类器能够更好地区分具有相似光谱但不同高度的地物。HSI与LiDAR数据形成优势互补,综合HSI和LiDAR数据能够更好地区分不同植被。

目前,已有不少学者联合HSI与LiDAR开展了森林、红树林等分类方法的研究。Tian^[13]等人提取了大量的HSI特征并进行特征选择,将这些特征与LiDAR特征相结合,采用面向对象的分类器对

广西高峰林场的零散本地树种进行了准确分类,准确率高达91.59%,Kappa系数为0.897。Mayra^[14]等基于HSI和LiDAR以及大量实测数据,采用3D-CNN算法对芬兰北部地带森林进行树种区分,达到0.86的总体F1-score和87%的总体分类精度。Li^[15]等利用WorldView-3、机载HSI和LiDAR点云数据,准确完成了多层红树林绘制,总体分类精度在86%~88%之间。Cao^[16]等利用HSI和LiDAR点云数据,对中国最大的人工红树林进行分类,结果表明,结合冠层高度信息可以明显提高分类精度,所提出的方法取得了97.22%的总体精度和0.968 6的Kappa系数。以上研究表明,HSI和LiDAR数据联合进行植被分类能够有效地提高植被分类的精度。但现有大量HSI、LiDAR联合分类研究都是针对森林、红树林等相对较大的地物尺度的像素级分类。针对黄河口地区的低矮草本、灌木植被的小尺度、高空间分辨率的湿地植被像素级分类研究较少,这类数据往往具有更强的光谱变异性,导致分类结果容易产生“椒盐”现象。另外,由于植被间结构复杂而导致LiDAR点云密度不均匀,也会使分类结果产生一定的“椒盐”现象。

本文以黄河三角洲自然保护区一处典型湿地植被混生地带为研究区,综合利用无人机HSI和LiDAR数据,提取了植被的光谱、纹理和高度等特征为分类提供更多的特征维度,并提出了一种结合空谱特征融合和通道注意力机制的双分支卷积神经网络(SSF-C-DBCNN)。光谱注意力机制通过自动关注高质量、具有更大贡献的光谱波段,将更多注意力集中在对目标分类有意义的光谱区域上,削弱噪声波段和光谱变异,从而增强模型的鲁棒性,提高模型的泛化能力,减少“椒盐”现象的出现。而空间注意力机制可以学习到更多的局部、全局空间信息,将更多的注意力集中在点云密集的区域,提高这些区域的特征表达能力和模型对空间位置重要性的感知和判断能力,从而抑制密度不均匀点云的稀疏空洞干扰造成的“椒盐”现象。最后,融合双分支空谱特征并引入通道注意力机制,进一步提高模型对融合特征的利用效果,以更准确和鲁棒的方式进行图像分类任务。探究了双分支多重注意力机制在提高分类精度和抵抗“椒盐”现象方面的作用,以及植被指数、纹理特征和LiDAR特征在对黄河口湿地植被分类中的作用。

1 研究区与数据

1.1 研究区概况

本文的研究区如图 1 所示, 为山东省东营市垦利区黄河三角洲国家级自然保护区内的一处典型湿地植被混生区, 位于 119° 9'25.62"E~

119°9'36.84"E, 37°45'45.83"N~37°45'52.94"N, 属于暖温带半湿润大陆性季风气候, 受海陆热力性质差异影响形成温带季风气候, 四季分明, 夏季高温多雨, 冬季寒冷干燥^[17]。该地区地势平坦, 除裸地外, 有天然柳林、芦苇、碱蓬、怪柳、荻草五种典型湿地植被, 混生程度较高。

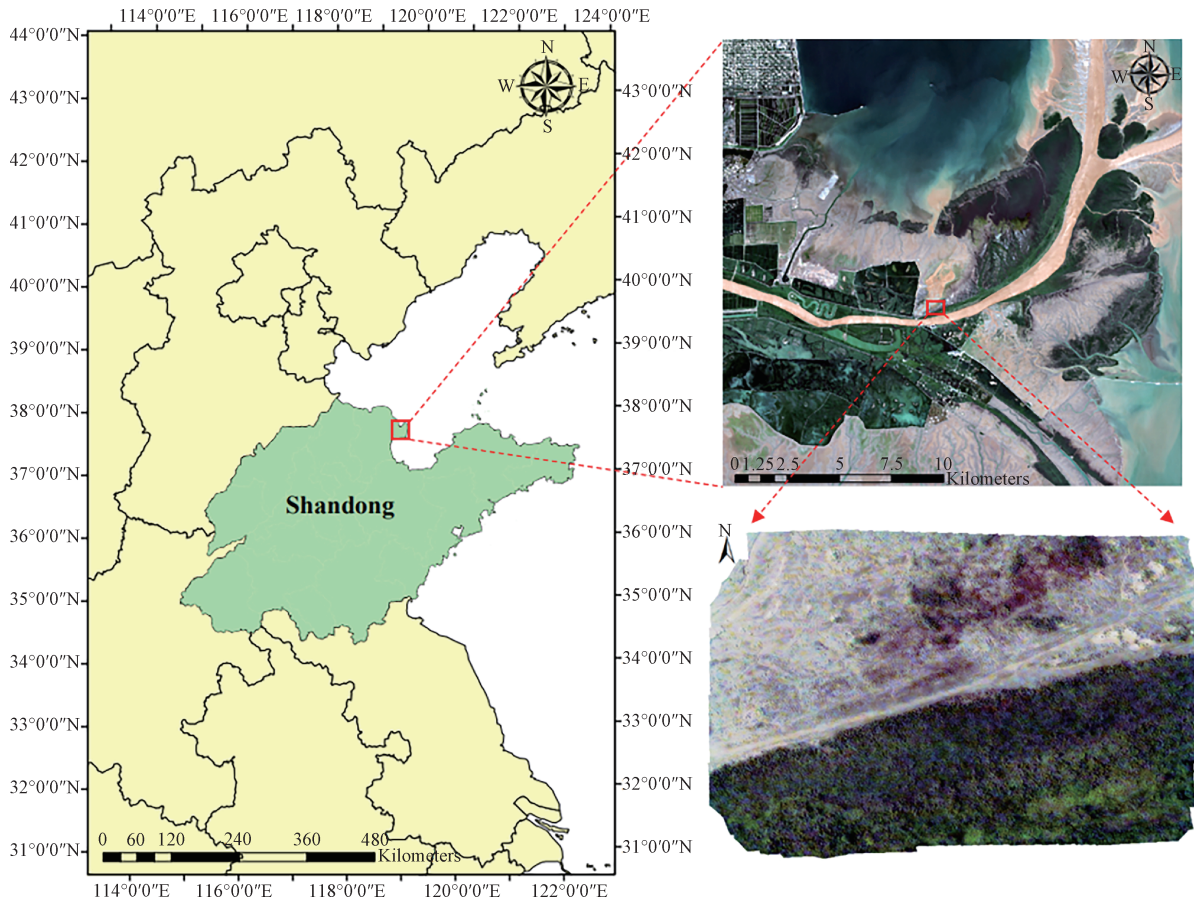


图 1 研究区地理位置

Fig. 1 Geographical location of the study area

1.2 数据采集

HSI 为 DJI M600 PRO 无人机搭载 Cubert-S185 高光谱相机所拍摄, 拍摄区域约 206 m×221 m, 面积 66.75 亩, 飞行高度 100 m, 对应空间分辨率 4 cm。将多条航带的原始影像经辐射定标、影像拼接、对齐等操作, 得到研究区的完整 HSI, 如图 2(a)所示, 将其所有波段全部导出, 共 125 个光谱波段, 每两个波段之间 4 nm 的光谱间隔, 光谱范围 450 nm~950 nm。

LiDAR 数据采用 FeiMa D2000 无人机飞行平台, 搭载 D-LiDAR 2000 轻型机载激光雷达系统获取, 具有高精度、高密度、穿透能力强(三回波)的

特点。采集时飞行高度 50 m, 航向、旁向重叠度均为 50%, 点云密度大约为 226 m²。利用飞马品牌的专业软件对 LiDAR 原始点云进行 GPS 轨迹解算、点云解算、特征点提取、航带平差、去冗余、去噪等流程后, 得到研究区的标准点云数据, 如图 2(b)所示。

采用 DJI Phantom4 Pro 无人机搭载 CMOS 相机, 飞行高度为 74 m, 获取了 1.85 cm 分辨率的研究区 RGB 影像, 如图 2(c)所示, 用以辅助影像解译。

通过实地踏勘、现场目视解译和 UAV RGB 影像辅助解译, 研究区内裸地(Bare land)和 5 种植被

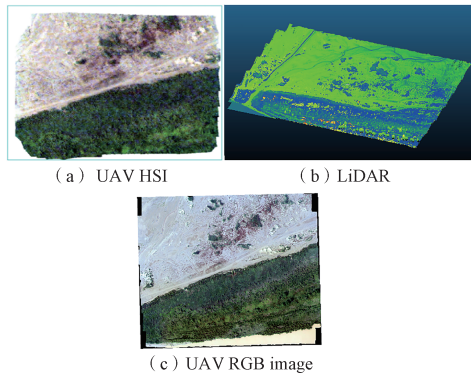


图2 无人机数据
Fig. 2 UAV data

类型包括天然柳林(Natural willow forest)、芦苇(Reed)、碱蓬(Suaeda salsa)、怪柳(Tamarix chinensis)、荻草(Silver grass)共获取了699个已知样本矢量多边形,共50 926个样本,样本位置及分布如图3所示。从每类样本中随机选取5%作为训练样本,共计2 543个,其余样本作为测试样本对分类结果进行定量评价,共计48 383个。表1显示了训练样本和测试样本的详细信息。




图3 解译样本位置及分布

Fig. 3 Location and distribution of vegetation samples within the study area

表1 训练、测试样本设置
Table 1 Training and test samples settings

颜色	类别	训练	测试
	Natural willow forest	38	737
	Reed	616	11712
	Suaeda salsa	127	2419
	Tamarix chinensis	877	16667
	Silver grass	859	16339
	Bare land	26	509
总计		2543	48383

1.3 数据配准

HSI和LiDAR由于成像原理不同,在空间上存在一定差异,必须通过几何配准实现坐标系、空间位置的统一,为数据融合提供先决条件。近年来,基于不同源的遥感数据融合,在人工智能、图像处理、无人驾驶等领域已广泛应用^[18-21],而几何配准是不同源数据间融合的关键问题。本论文基于共同特征点,利用共线方程计算相似度测度进行配准。用于配准的参考影像为LiDAR标准点云插值生成的0.25 m分辨率的数字表面模型(Digital Surface Model, DSM),对预处理后的无人机HSI进行配准。将两者坐标系统一至WGS-84 UTM 50N下,再将HSI重采样至与DSM空间分辨率一致,实现像素级的配准。为了减小影像畸变提高配准精度,在整幅影像上均匀选取了20~30个特征点,并进行2次多项式拟合,重复多次配准,删除误差较大的特征点,最终配准精度在2~3个像素之间,如图4所示,足以满足实验要求。




图4 配准前后对比

Fig. 4 Comparison before and after registration

2 方法

2.1 HSI特征提取及优选

原始HSI分辨率高,数据量大,对其进行主成

分分析(Principal Component Analysis, PCA),减小数据量,提取主要特征。从新的主成分(Principal Component, PC)中,根据每个主成分特征值大小及保留原始影像信息的含量,最终确定降维后的

波段数为 2, 保留原始图像 98.5% 的信息。

HSI 能够提供丰富的地物水平结构信息。通过不同波段组合计算得到的遥感指数, 对不同地物的敏感度不同, 能有效提高地物间的可区分性, 增加分类精度。常用的遥感指数包括植被指数 (Vegetation Index, VI) 和纹理特征。植被指数能反映植被生长情况, 对植被生理特性有一定指示意义^[22]。灰度共生矩阵 (Gray Level Co-occurrence Matrix, GLCM) 反映了图像中像素点及其周围空间邻域的灰度分布情况, 利用纹理特征可以很好地描述图像景物的表面特性^[23]。

基于 HSI 部分原始波段和 PC1、PC2, 分别提取了差值植被指数 (DVI)、比值植被指数 (RVI)、绿色归一化植被指数 (GNDVI)、归一化植被指数 (NDVI)、红边归一化植被指数 (NDVI_{RE})、重归一化植被指数 (RDVI)、抗大气植被指数 (ARVI)、土壤调整指数 (SAVI)、优化土壤调整指数 (OSAVI)、绿色土壤调整指数 (GSAVI)、红边土壤调整指数

(RESAVI)、增强植被指数 (EVI)、三角植被指数 (TVI)、全球环境监测植被指数 (GEMI)、修改叶绿素吸收反射指数 (MCARI1)、红边叶绿素指数 (CIRE)、改进的红边简单比率指数 (MSR_{RE})、DATT 共 18 种植被指数以及均值 (Mean)、方差 (Variance)、协同性 (Homogeneity)、对比度 (Contrast)、相异性 (Dissimilarity)、熵 (Entropy)、角二阶矩 (Second moment)、相关性 (Correlation) 共 8 种纹理特征。

为避免变量冗余, 提升分类效率, 探究不同 HSI 特征对分类的作用, 采用随机森林特征优选, 对 HSI 特征进行筛选。提取的 HSI 特征包括绿 (Green)、红 (Red)、红边 (RE)、近红 (NIR) 4 个原始波段, 上述 18 个衍生的植被指数以及 16 个纹理特征, 采用 Gini 指数作为特征重要性评估的度量指标, 选出最优特征, 得到不同 HSI 特征的贡献如图 5 所示。最终保留了 12 个对分类贡献较高的 HSI 特征。

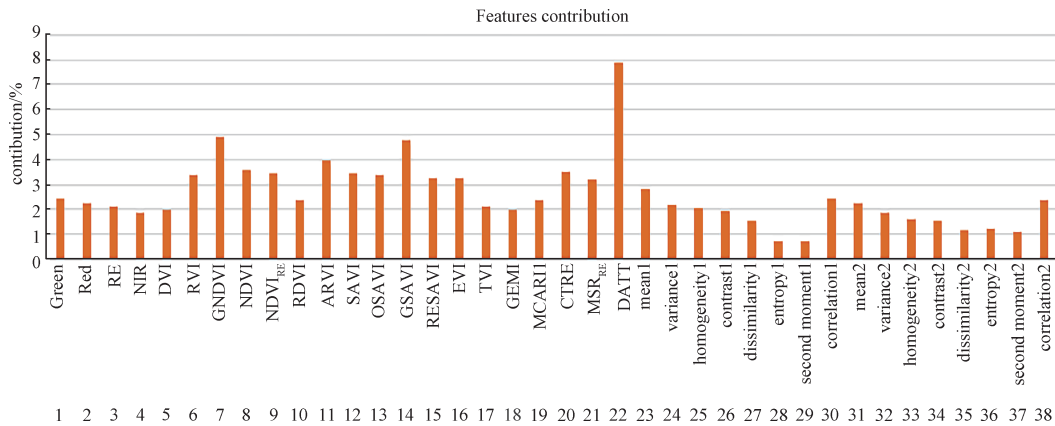


图 5 HSI 特征贡献度

Fig. 5 HSI Features contribution

2.2 LiDAR 结构特征提取

LiDAR 数据经预处理得到 LAS 格式的标准点云, 用以制作研究区的 DSM 以及反射强度栅格 (Intensity grid)。DSM 是一个包含地物、植被、地面高程信息的地面高程模型。采用局部加权回归 (Loess) 方法, 一种基于局部统计和回归的插值方法^[24], 可以在不需要更多数据的前提下, 利用点云数据生成光滑的、连续的高程表面。Intensity 表示激光在击中对象表面时反弹回来的能量强度, 可以用来计算地表物质的反射率和其他表征物体特性的指标。利用 Arcgis10.6 将点云数据中的反射强度值转换为栅格数据, 生成 Intensity grid。

已有研究证明, 植被冠层高度模型 (Canopy Height Model, CHM) 对植被分类有很大的提升作用^[25-27]。获取 CHM 的方法是提取 LiDAR 点云覆盖地区的 DSM 和数字高程模型 (Digital Elevation Model, DEM), DSM 与 DEM 作差得到 CHM^[28]。本文基于 CloudCompare, 利用布料模拟算法 (Cloth Simulation Filter, CSF) 提取了研究区的 DEM^[29]。CSF 原理是将原始点云倒转过来, 一块布从上方掉落到倒置的表面, 如图 6 所示。通过分析布的节点和 LiDAR 点之间的相互作用, 确定布的形状, 最终实现地面点和非地面点的分离, 得到非地面点云和地面点云。将得到的地面点云进

行栅格化, 得到DEM, 进而利用DSM与DEM作差得到CHM, 如图7所示。




图6 CSF算法基本原理

Fig. 6 Basic principle of CSF

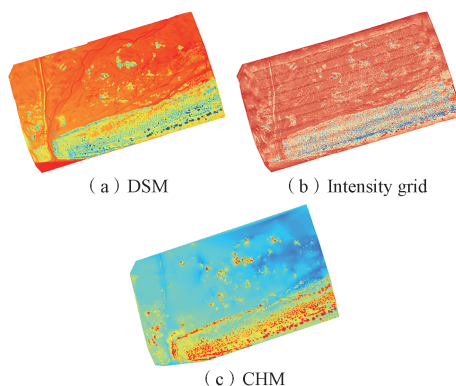


图7 LiDAR结构特征

Fig. 7 LiDAR structural features

2.3 SSF-C-DBCNN

本文提出的SSF-C-DBCNN(图8)采用CNN为基本架构, 将包含卷积层(Convolutional Layer)、池化层(Pool Layer)、全连接层(FC Layer)的单分支2D-CNN扩展至两个并行的分支, 分别进行不同的提取任务, 变相提高了网络模型的卷积深度, 通过在两个分支上分别设置不同的参数、权重及

光谱、空间注意力机制, 输入数据同时通过两个分支进行前向传播, 通过损失函数来计算两个分支输出之间的差异, 可以捕捉到输入数据的不同方面和多维特征, 学习到更多的特征表示, 并提高模型在复杂任务上的准确性和鲁棒性^[30]。

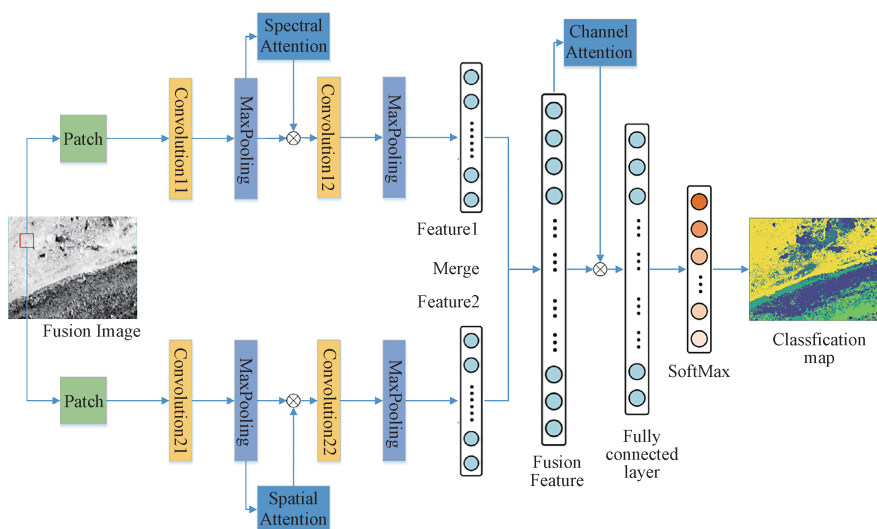


图8 SSF-C-DBCNN框架

Fig. 8 The framework of proposed SSF-C-DBCNN

分支一引入光谱注意力机制(Spectral Attention)如图9所示, 首先通过平均池化(Average Pooling)求均值获取输入特征的光谱信息, 将其进行维度转换, 使用一个Conv_{1×1}对光谱信息进行特征变换, 将特征维度进行压缩, 再使用另一个Conv_{1×1}将变换后的光谱信息进行特征变换, 将特征维度恢复为输入通道数, 应用Sigmoid激活函数将其限制在0到1之间, 得到注意力权重。最后, 将输入特征和注意力权重逐元素相乘, 得到注意力增强后的特征^[31]。




图9 光谱注意力机制

Fig. 9 Spectral attention mechanism

分支二引入空间注意力机制(Spatial Attention), 如图10所示, 首先对输入特征进行平均池化(Average Pooling)和最大池化(MaxPooling), 分别提取全局平均值和最大值特征, 然后将这两种特征经过

Conv_2D 卷积和 Leaky ReLU 激活函数处理后, 进行拼接, 最后通过元素相乘的方式将注意力权重应用到原始特征上, 得到增强后的特征^[32]。




图 10 空间注意力机制

Fig. 10 Spatial attention mechanism

将两个并行 2D-CNN 分支提取的空谱特征进行合并, 引入通道注意力机制(Channel Attention)(图 11), 首先对输入特征进行自适应平均池化(Adaptive Average Pooling)和自适应最大池化(Adaptive MaxPooling), 得到平均池化特征和最大池化特征。对这两种特征分别进行特征变换, 通过 Conv_2D 卷积和 Leaky ReLU 激活函数处理后得到对应的特征表示。将平均池化特征和最大池化特征对应位置上的特征相加, 得到通道注意力的加权特征。注意力加权特征通过 Tanh 激活函数处理, 将输出值限制在 -1~1 之间。最后, 将输入特征与注意力加权特征逐元素相乘, 得到增强后的特征^[32]。




图 11 通道注意力机制

Fig. 11 Channel attention mechanism

3 实验结果与分析

3.1 实验设置

为探究多源特征在黄河口湿地植被分类中的作用和双分支多重注意力机制在提高分类精度和抵抗“椒盐”现象方面的作用, 以降维后的 HSI 主成分 PC1-2 作为基础影像, 其分类结果作为对照组 (Control group), 设置了 3 种数据融合方案 (Strategy1-3), 见表 2。比较不同融合方案在多种分类器上的分类效果, 利用每一类的 F1-score、OA、Kappa 系数等多重评价指标进行精度评价。

表 2 实验方案设置

Table 2 Experimental strategies settings

组别	数据组合
Control group	PC1-2
Strategy 1	PC1-2 + HSI 特征
Strategy 2	PC1-2 + LiDAR 特征
Strategy 3	PC1-2 + HSI 特征 + LiDAR 特征

3.2 精细分类结果与分析

不同融合方案与多种分类器联合分类精度总体对比如图 12 所示, 精细分类图如图 13 所示, 精度评价见表 3~表 6。表 3 中, 与仅使用 HSI 分类相比, 三种融合策略的分类精度均显著提高。加入优选 HSI 特征和 LiDAR 特征分别见表 4 和表 5, HSI 特征在简单分类器上的 OA 和 Kappa 系数增量比 LiDAR 特征略高。而 LiDAR 特征在具有卷积操作的多个网络上表现则更好。总体来说, LiDAR 特征在提高精度方面较 HSI 特征更加明显。同时加入 HSI 特征和 LiDAR 特征, 所有算法都实现了最高的 OA 和 Kappa 系数, 见表 6。

通过以上结果, 可以发现:

① 从图 13 精细分类图来看, 仅使用 HSI 及其衍生的光谱、纹理特征, 只有部分稀疏分布的芦苇能够被识别, 其他植被均无法有效识别, 整体分类效果很差。加入 LiDAR 特征后, 分类的准确性有明显提升, 说明 LiDAR 特征在提高分类结果准确性的作用上远超 HSI 特征。将 HSI 特征和 Li-

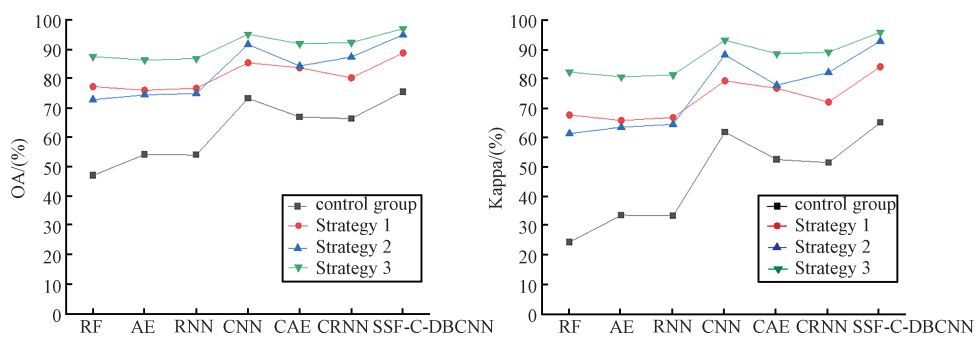


图 12 OA、Kappa 系数总体对比

Fig. 12 Overview of OA and Kappa of different fusion strategies combined with multiple classifiers




图 13 精细分类图

Fig. 13 Vegetation fine classification maps

表 3 Control group 联合分类精度评价

Table 3 Accuracy assessment of different classification methods in the control group

Methods	RF	AE	RNN	CNN	CAE	CRNN	SSF-C-DBCNN
Class	F1-score						
Natural willow forest	58.08	66.45	63.99	66.45	69.23	55.99	78.86
Reed	30.29	26.28	27.05	51.97	40.15	38.33	57.66
Suaeda salsa	73.82	77.60	77.22	89.44	89.60	82.46	93.03
Tamarix chinensis	48.29	52.77	51.20	78.70	71.50	71.81	79.93
Silver grass	51.15	61.59	61.83	78.46	72.62	72.83	79.62
Bare land	78.54	81.43	81.95	98.31	96.31	95.41	97.97
OA	47.08	54.23	54.08	73.37	67.02	66.50	75.55
Kappa	24.59	33.74	33.51	61.99	52.68	51.60	65.24

表 4 Strategy 1 联合分类精度评价

Table 4 Accuracy assessment of different classification methods in Strategy 1

Methods	RF	AE	RNN	CNN	CAE	CRNN	SSF-C-DBCNN
Class	F1-score						
Natural willow forest	90.57	87.11	89.70	88.97	89.27	83.80	94.91
Reed	73.08	72.42	71.23	78.29	78.38	73.75	84.21
Suaeda salsa	91.97	91.24	91.36	97.81	95.98	95.53	95.30
Tamarix chinensis	73.66	72.72	73.45	84.72	81.42	77.57	87.68
Silver grass	81.53	79.86	81.33	89.04	87.53	85.14	92.33
Bare land	76.59	64.41	80.79	98.52	88.06	98.36	87.23
OA	77.40	76.14	76.83	85.52	83.79	80.40	88.85
Kappa	67.84	66.00	66.97	79.46	76.91	72.24	84.24

表 5 Strategy 2 联合分类精度评价

Table 5 Accuracy assessment of different classification methods in Strategy 2

Methods	RF	AE	RNN	CNN	CAE	CRNN	SSF-C-DBCNN
Class	F1-score						
Natural willow forest	66.49	67.47	65.97	77.16	75.30	75.75	81.80
Reed	58.89	59.08	61.92	87.58	75.76	81.51	93.05
Suaeda salsa	87.88	89.78	89.11	95.93	91.90	93.48	96.93
Tamarix chinensis	73.43	75.41	75.87	91.51	85.07	86.53	94.67
Silver grass	79.86	80.93	81.20	94.64	89.01	91.99	97.00
Bare land	87.03	90.85	88.77	99.61	95.45	98.63	98.26
OA	72.94	74.55	75.06	91.75	84.43	87.49	95.04
Kappa	61.53	63.70	64.66	88.29	77.96	82.28	92.97

DAR 特征同时加入, 分类精度和准确性进一步得到提升, 其中 LiDAR 特征仍占据主导地位。分析上述结果原因, 从水平和垂直结构两个方面分析研究区共 6 种植被的可区分性。水平结构上, 计算了感兴趣区范围内 6 种植被类型的平均光谱曲线, 如图 14(a)所示, 除裸地与柽柳外, 其他 4 种植被的光谱曲线呈现出高度的相似性, 芦苇、碱蓬、荻草的光谱曲线近乎重合, 导致 HSI 特征虽然能提

升一定的分类精度, 但对植被分类的作用受到极大的限制。垂直结构上, 计算了 6 种植被类型的平均高度, 如图 14(b)所示, 具有较为明显的高度差异, 证明 LiDAR 特征能够补充单纯依靠光谱特征进行分类的不足, 提供其他能够有效区分植被的特征维度和有用信息, 证明了 HSI、LiDAR 联合分类具有充分的理论和实际可行性。

表 6 Strategy 3 联合分类精度评价
Table 6 Accuracy assessment of different classification methods in Strategy 3

Methods	RF	AE	RNN	CNN	CAE	CRNN	SSF-C-DBCNN
Class	F1-score						
Natural willow forest	89.98	83.82	80.19	94.49	92.75	92.12	95.62
Reed	83.86	82.96	82.48	93.57	88.88	89.22	96.08
Suaeda salsa	94.94	94.86	95.33	98.59	97.07	97.13	98.52
Tamarix chinensis	85.54	84.04	84.86	94.46	90.29	90.80	96.69
Silver grass	91.31	90.19	91.09	96.67	95.23	95.42	98.28
Bare land	85.66	87.09	91.56	99.03	91.94	98.06	96.68
OA	87.63	86.45	86.95	95.24	91.99	92.38	97.15
Kappa	82.47	80.79	81.46	93.26	88.68	89.20	95.97

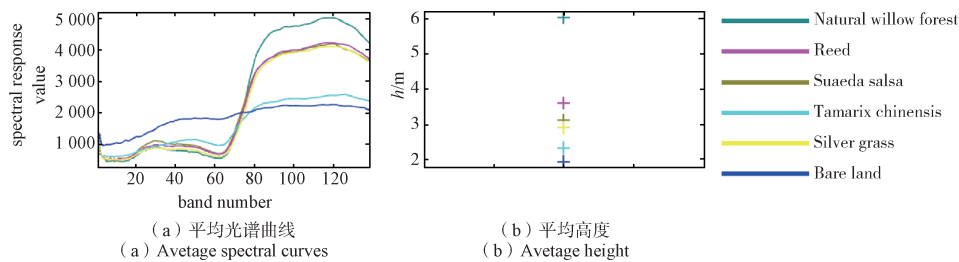


图 14 6种植被类型水平、垂直结构特征对比

Fig. 14 Comparison of horizontal and vertical structural characteristics of 6 vegetation types

② 针对黄河口湿地的复杂植被群落分布，深度学习方法的分类效果更为显著。而几种典型深度学习方法中，带有卷积操作的特征提取模型对稀疏碱蓬的提取效果更好，具有更好的特征提取和表达能力。但是这些方法的分类结果均出现了不同程度的“椒盐”现象，与真实地物分布不符。本文提出的方法，应用双分支多重注意力机制，有效减少了混生植被的错分以及稀疏分布的单株碱蓬之间的粘连现象，在提升精度的同时，很大程度减少了分类结果的“椒盐”现象，使分类结果更加贴合真实地物分布。

③ 此外，分析随机森林 HSI 特征优选的结果，发现对分类精度影响较大的 HSI 特征均为植被指数，纹理特征重要性普遍较低，因此纹理特征并不适用于黄河口湿地的小尺度复杂植被识别和提取，对混生植被精细分类的作用仍有待考究。

4 结束语

本文以黄河三角洲自然保护区内一处典型湿地混生植被为研究区，融合无人机 HSI、LiDAR 数据，提取了多源影像特征并利用随机森林进行特征优选，提出一种结合空谱特征融合和通道注意力机制的双分支卷积神经网络 SSF-C-DBCNN。实

验结果表明，HSI 特征和 LiDAR 结合能够提高湿地分类的精度。另外，双分支多重注意力机制在抵抗小尺度、高分辨率遥感影像以及 LiDAR 数据在湿地植被精细分类结果出现“椒盐”现象的问题中是可行且有效的。研究结果为湿地植被的精细分类提供了重要参考。

本文利用 HSI 和 LiDAR 联合对黄河口湿地植被进行精细分类取得了较好的结果，但对 LiDAR 提取的相关结构特征并不全面，后续研究将考虑引入更多 LiDAR 的结构特征，如表面法向量、点云密度、叶面积指数等，充分挖掘 LiDAR 在黄河口湿地植被精细分类中的有用信息。另外，由于黄河口现场调查的时间、环境、天气等客观原因，本次实验数据采集未采集多时序的现场影像，采集的湿地植被也难以包含互花米草，后续的黄河口湿地研究工作将考虑采集不同时间，不同区域(包含互花米草)的数据进行更全面的研究，进而为黄河三角洲自然保护区的管理、保护和恢复提供理论参考和技术支撑。

参考文献

[1] 李贺颖, 张建辰, 郭建忠. 黄河流域湿地景观时空演变格局分析[J]. 测绘通报, 2021(10): 28-33.

- LI heyang, ZHANG Jianchen, GUO Jianzhong. Spatio-temporal evolution pattern of wetland landscape in the Yellow River Basin[J]. *Bulletin of Surveying and Mapping*, 2021(10): 28-33.
- [2] 孔梅, 曹惠明, 高兴国, 等. 黄河三角洲自然保护区国土空间变化遥感监测与评价[J]. *海洋环境科学*, 2021, 40(2): 272-276.
KONG Mei, CAO Huiming, GAO Xingguo, et al. Remote sensing monitoring and evaluation of land space change in the Yellow River Delta Nature Reserve[J]. *Marine Environmental Science*, 2021, 40(2): 272-276.
- [3] 潘晓骏, 聂晨晖, 唐伟, 等. 湿地信息遥感监测与演变模拟研究进展[J]. *测绘与空间地理信息*, 2020, 43(7): 79-83.
PAN Xiaojun, NIE Chenhui, TANG Wei, et al. Review on wetland information monitoring and evolution simulation using remote sensing[J]. *Geomatics & Spatial Information Technology*, 2020, 43(7): 79-83.
- [4] 张艺伟, 郭焱培, 唐荣, 等. 高光谱遥感在植物多样性研究中的应用进展与趋势[J]. *遥感学报*, 2023, 27(11): 2467-2483.
ZHANG Yiwei, GUO Yanpei, TANG Rong, et al. Progress and trends of application of hyperspectral remote sensing in plant diversity research[J]. *National Remote Sensing Bulletin*, 2023, 27(11): 2467-2483.
- [5] 乔雯钰, 龙亦凡, 付杰. 基于波段组合的高光谱数据湿地分类研究[J]. *北京测绘*, 2020, 34(5): 651-656.
QIAO Wenyu, LONG Yifan, FU Jie. Study on wetland classification of hyperspectral data based on band combination[J]. *Beijing Surveying and Mapping*, 2020, 34(5): 651-656.
- [6] 徐美论, 李忠伟, 王雷全, 等. 联合 Bi-LSTM 和注意力加强多尺度卷积的黄河三角洲湿地高光谱图像分类方法研究[J]. *海洋科学*, 2023, 47(5): 27-40.
XU Meilun, LI Zhongwei, WANG Leiquan, et al. Combined Bi-LSTM and attention enhancement multiscale convolution for wetland hyperspectral image classification in the Yellow River Delta[J]. *Marine Sciences*, 2023, 47(5): 27-40.
- [7] 任广波, 张杰, 汪伟奇, 等. 基于 HJ-1 高光谱影像的黄河口芦苇和碱蓬生物量估测模型研究[J]. *海洋学研究*, 2014, 32(4): 8.
REN Guangbo, ZHANG Jie, WANG Weichi, et al. Reeds and suaeda biomass estimation model based on HJ-1 hyperspectral image in the Yellow River Estuary[J]. *Journal of Marine Sciences*, 2014, 32(4): 8.
- [8] 韩月, 柯樱海, 王展鹏, 等. 资源一号 02D 卫星高光谱数据黄河三角洲湿地景观分类[J]. *遥感学报*, 2021(6): 1387-1399.
HAN Yue, KE Yinghai, WANG Zhanpeng, et al. Classification of the Yellow River Delta wetland landscape based on ZY-1 02D hyperspectral imagery[J]. *National Remote Sensing Bulletin*, 2021(6): 1387-1399.
- [9] 王建步, 张杰, 马毅, 等. 黄河口湿地典型地物类型高光谱分类方法[J]. *海洋学研究*, 2014, 32(3): 36-41.
WANG Jianbu, ZHANG Jie, MA Yi, et al. Classification method of hyperspectral image in typical surface feature of Huanghe River estuary wetland[J]. *Journal of Marine Sciences*, 2014, 32(3): 36-41.
- [10] 李晓敏, 张杰, 马毅, 等. 基于无人机高光谱的外来入侵种互花米草遥感监测方法研究——以黄河三角洲为研究区[J]. *海洋科学*, 2017, 41(4): 98-107.
LI Xiaomin, ZHANG Jie, MA Yi, et al. Study on monitoring alien invasive species *Spartina alterniflora* using unmanned aerial vehicle hyperspectral remote sensing—a case study of the Yellow River Delta[J]. *Marine Sciences*, 2017, 41(4): 98-107.
- [11] 张强. 湿地植被遥感分类研究进展[J]. *世界林业研究*, 2019(3): 49-54.
ZHANG Qiang. Research progress in wetland vegetation classification by remote sensing[J]. *World Forestry Research*, 2019(3): 49-54.
- [12] LEFSKY M A, COHEN W B, PARKER G G, et al. Lidar remote sensing for ecosystem studies Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest[J]. *Psychological Reports*, 2002, 46(1): 927-930.
- [13] TIAN X, ZHANG X, WU Y. Classification of planted forest species in southern China with airborne hyperspectral and LiDAR data[J]. *Journal of forest research*, 2020, 25(6): 369-378.
- [14] MAYRA J, KESKI-SAARI S, KIVINEN S, et al. Tree species classification from airborne hyperspectral and LiDAR data using 3D convolutional neural networks[J]. *Remote Sensing of Environment: An Interdisciplinary Journal*, 2021(256-): 256.
- [15] LI K F T. Mapping multi-layered mangroves from multi-spectral, hyperspectral, and LiDAR data[J]. *Remote Sensing of Environment: An Interdisciplinary Journal*, 2021, 258(1): 112403.
- [16] CAO Jingjing, LIU Kai, ZHUO Li, et al. Combining UAV-based hyperspectral and LiDAR data for mangrove

- species classification using the rotation forest algorithm[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 1021-10.
- [17] 高瑞, 王志勇, 周晓东, 等. 利用多时相遥感监测与分析黄河三角洲湿地变化动态[J]. *测绘通报*, 2021(4): 22-27.
GAO Rui, WANG Zhiyong, ZHOU Xiaodong, et al. Monitoring and analysis of wetland change dynamics in the Yellow River Delta using multi-temporal remote sensing[J]. *Bulletin of Surveying and Mapping*, 2021(4): 22-27.
- [18] CLARK M L, ROBERTS D A, EWEL J J, et al. Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors[J]. *Remote Sensing of Environment*, 2011, 115(11): 2931-2942.
- [19] 李莹莹, 吴昊, 俞雷, 等. 高分辨率 SAR 和可见光图像同名点自动匹配技术[J]. *测绘通报*, 2014(5): 66-70.
LI Yingying, WU Hao, YU Lei, et al. Automatic matching of tie-points between high-resolution SAR and optical images[J]. *Bulletin of Surveying and Mapping*, 2014(5): 66-70.
- [20] 王飞, 高小伟, 高宁, 等. 面向海洋应用的无人机遥感图像配准研究[J]. *测绘通报*, 2017(11): 123-127.
WANG Fei, GAO Xiaowei, GAO Ning, et al. Remote sensing image registration of unmanned aerial vehicle for marine applications[J]. *Bulletin of Surveying and Mapping*, 2017(11): 123-127.
- [21] 项谦和, 杜娟, 陈春雷, 等. 沿海矿山生态环境修复中遥感影像自动配准方法的应用[J]. *测绘通报*, 2020(7): 58-63.
XIANG Qianhe, DU Juan, CHEN Chunlei, et al. Application of automatic registration method of remote sensing image in ecological environment restoration of coastal mines[J]. *Bulletin of Surveying and Mapping*, 2020(7): 58-63.
- [22] 田庆久, 闵祥军. 植被指数研究进展[J]. *地球科学进展*, 1998, 13(4): 327-333.
TIAN Qingjiu, MIN Xiangjun. Advances in study on vegetation indices[J]. *Advances in Earth Science*, 1998, 13(4): 327-333.
- [23] 程志会, 谢福鼎. 基于空间特征与纹理信息的高光谱图像半监督分类[J]. *测绘通报*, 2016(12): 56-59, 73.
CHENG Zhihui, XIE Fuding. Semi-supervised classification for hyperspectral image based on spatial features and texture information[J]. *Bulletin of Surveying and Mapping*, 2016(12): 56-59, 73.
- [24] CLEVELAND W S. Robust locally weighted regression and smoothing scatterplots[J/OL]. *Publications of the American Statistical Association* [2023-12-14].
- [25] 周焯, 刘云波, 郑丽波, 等. 多平台点云数据的单木参数提取精度分析[J]. *测绘通报*, 2022(7): 168-172.
ZHOU Ye, LIU Yunbo, ZHENG Libo, et al. Precision analysis of single tree parameter extraction for multi-platform point cloud data[J]. *Bulletin of Surveying and Mapping*, 2022(7): 168-172.
- [26] REITBERGER J, KRZYSZEK P, STILLA U. Analysis of full waveform LIDAR data for the classification of deciduous and coniferous trees[J]. *International Journal of Remote Sensing*, 2008, 29(5): 1407-1431.
- [27] 吴培强, 任广波, 张程飞, 等. 无人机多光谱和 LiDAR 的红树林精细识别与生物量估算[J]. *遥感学报*, 2022, 26(6): 1169-1181.
WU Peiqiang, REN Guangbo, ZHANG Chengfei, et al. Fine identification and biomass estimation of mangroves based on UAV multispectral and LiDAR[J]. *National Remote Sensing Bulletin*, 2022, 26(6): 1169-1181.
- [28] NI W J, LIU J L, ZHANG Z Y, et al. Evaluation of UAV-based forest inventory system compared with LiDAR data[C]//In 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), IEEE, 2015.
- [29] ZHANG W, QI J, WAN P, et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation [J]. *Remote Sensing*, 2016, 8(6): 501-519.
- [30] GAO F, HUANG T, WANG J, et al. Dual-branch deep convolution neural network for polarimetric SAR image classification[J]. *Applied Sciences*, 2017, 7(5): 447.
- [31] MEI Xiaoguang, PAN Erting, MA Yong, et al. Spectral-spatial attention networks for hyperspectral image classification[J]. *Remote Sensing*, 2019, 11(8): 963.
- [32] GUO T, WANG R Z, LUO F L, et al. Dual-view spectral and global spatial feature fusion network for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 1-13.

[作者简介]

- 许明明 1990年生, 副教授, 硕士生导师。
刘 航 1999年生, 硕士研究生。
窦庆文 1969年生, 工程师。
刘善伟 1982年生, 教授。
盛 辉 1972年生, 副教授, 硕士生导师。

(本文编辑: 杨秀丽)