

基于 AlexNet 的近岸水生植物光谱分类及特征光谱分析

郑宗生, 刘贝*, 卢鹏, 王振华, 邹国良, 赵家惠, 李云飞

上海海洋大学信息学院, 上海 201306

摘要 水生植物能够净化污染物和抑制藻类生长,在生态系统重建方面具有重要的应用价值。光谱分析作为植物种类识别的一种方法,具有无接触、快速、无污染等特点。受周围水环境的影响,绿色水生植物的光谱特征峰比陆生植物更加难以区分,地面实测光谱数据不仅维度高,且存在大量重叠谱带和背景干扰,特征光谱不明显;同时,通过地面实测获取样本数据较为困难,适用于深度学习的地面光谱数据集较少。针对以上问题,本文提出了一种基于一阶导数法结合 AlexNet 网络的分类模型。本团队以 2019 年 9—10 月上海河道内 4 种优势种群的近岸挺水水生植物为研究对象,使用地物光谱仪采集 4 种水生植物叶片部位的光谱信息。实验中,首先使用 4 种光谱分析法对原始数据进行预处理,比较预处理前后分类模型的准确率,其中一阶导数法结合 AlexNet 网络的分类模型对 4 种水生植物的分类精度最高,为 99.50%;然后分别选取样本数据的 40%、60% 和 80% 作为训练集,验证模型在小样本下的泛化能力;最后利用 Grad-CAM 算法对模型进行可视化,分析后发现本文模型提取的水生植物的特征光谱与现有研究结果一致。上述研究结果表明,本文模型能够有效提取水生植物的特征光谱,实现对 4 种水生植物的快速准确分类识别,为高光谱遥感卫星识别此 4 种水生植物提供了重要参考。

关键词 光谱学; 近岸水生植物; 深度学习; 光谱预处理; AlexNet 网络

中图分类号 O433.4

文献标志码 A

DOI: 10.3788/CJL220653

1 引言

水生植物作为退化水生生态系统恢复重建的先锋种,近年来成为了研究热点,特别是水烛、梭鱼草、香菇草、再力花等水生植物,已被广泛用于污染水域的修复^[1]。我国及欧美等国都相继出版了水生植物志方面的图书,并在水生植物区系的地理、生态、群落和植被,以及水生植物与环境的关系等方面进行了大量研究。我国在 20 世纪 80 年代才在水生植物方面进行了比较系统的研究工作,但在植物种类识别方面,还需要人工实地观察,难以快速、大量地识别出植物的种类。因此,建立一种快速有效的水生植物种类识别模型,可以提高水生生态环境监测效率,节约成本。

目前主要采用图像数字处理技术进行植物种类的识别研究。用于识别植物种类的图像数字处理技术可分为两类,一是基于植物成像图片进行识别^[2-4],二是基于植物光谱数据进行识别^[5-9]。基于植物成像图片进行识别的技术主要是依据植物叶片的基本特征,包括形状特征和纹理特征,进行识别,但是提取特征时需

要一定的专业知识,人工成本较高。基于光谱数据进行植物种类识别的技术通过测量植物的光谱信息建立植物光谱和植物种类的识别模型,可以快速识别出植物的种类。

目前,基于植物光谱数据的植物种类识别方法主要依据植物的光谱特征进行识别^[10-11],这些方法主要包括主成分分析法(PCA)、偏最小二乘法(PLS)、支持向量机(SVM)等传统的机器学习方法^[12]。由于光谱数据维度高,不同波长的吸收率或反射率之间存在多重相关性,所以建模时需要采用波长选择或特征表示的方法进行降维。波长选择方法依赖于对目标成分敏感的波段的先验知识或基于统计方法对各波段重要程度的评估结果,从原始光谱中挑选出部分有用波段的数据进行回归计算^[13-14]。汪星等^[15]使用连续统去除法结合支持向量机,实现了三类水生植物的分类,分类精度为 86.33%。张莹莹等^[16]将遥感影像的光谱特征、植被指数、水体指数、纹理特征等特征变量集成,采用分类与决策树方法建立了研究区湿地信息提取的决策树模型,并采用该模型对洪湖中的水生植物进行了分

收稿日期: 2022-03-09; 修回日期: 2022-03-31; 录用日期: 2022-04-25; 网络首发日期: 2022-05-09

基金项目: 国家自然科学基金(41671431)、上海市科委地方能力建设项目(19050502100)、国家海洋局数字海洋科学技术重点实验室开放基金(B201801034)、上海海洋大学科技发展专项基金(A2-2006-20-200211)

通信作者: *godbei@foxmail.com

类。Oyama 等^[17]测定了芦苇、荷花、菱角和苕菜 4 种水生植物在 350~2500 nm 波长范围内的反射光谱,使用浮藻指数 (FAI) 和归一化水体指数 (NDWI) 对 4 种水生植物进行了分类识别。Schmidt 等^[18]利用野外高光谱数据,采用 B 距离法和统计检验方法对荷兰盐沼湿地中的 27 种水生植被进行了可识别性研究。Luo 等^[19]基于 HJ-1A/B 数据,使用主成分变换和缨帽变换结合决策树方法对太湖中的不同水生植被进行了分类识别。Wang 等^[20]利用归一化植被指数时序数据和植物功能类型结合支持向量机模型对鄱阳湖中的水生植物种类进行了识别。

深度学习算法相比传统算法具有更强大的特征提取能力,已被广泛应用于光谱分类研究。赵勇等^[21]利用卷积神经网络 (CNN) 结合拉曼光谱建立了雌激素粉末分类模型,他们发现,与支持向量机、K 近邻 (KNN) 算法、随机森林、决策树等传统算法相比,卷积神经网络可以更好地对雌激素粉末进行分类。于重重等^[22]基于卷积神经网络建立了高光谱检测模型,实现了对小麦不完善粒的准确、快速、无损检测。王强等^[23]利用卷积神经网络结合 X 射线实现了异物水饺的识别,识别率优于 K-means 和 Otsu 等传统算法。

虽然深度学习算法已经应用在诸多领域^[24-26],但是应用在近岸水生植物光谱分类上还存在一些问题,且目前的应用较少。这主要是因为:1) 与陆生植物相比,水生植物的光谱数据存在大量重叠谱带,有效区分谱段更少,误分类问题更加严重;2) 适用于深度学习的光谱数据集较少,在地面进行光谱测量比较困难,样本数据较少。基于以上问题,本团队以上海河道内的 4 种主要近岸水生植物为研究样本,提出了一种基于 AlexNet 的近岸水生植物光谱分类方法。通过比较 AlexNet、CNN3 和 VGG16 网络模型对近岸水生植物光谱数据的分类效果和分类性能,选取最优网络结构;选取不同比例的样本,验证模型对小样本数据的泛化

能力;为消除光谱重叠谱带及背景干扰的影响,分别使用一阶导数、二阶导数及对数导数对样本数据进行预处理,并比较样本数据预处理前后模型分类效果,研究光谱预处理对网络模型的影响;利用 Grad-CAM 算法提取样本数据的深度特征,分析水生植物的敏感光谱,分析结果与现有研究结果一致。本研究结果表明,一阶导数法结合 AlexNet 网络的分类模型可以有效消除重叠谱带和背景干扰的影响,对 4 种近岸挺水水生植物光谱进行快速准确的分类识别。

2 材料与方法

2.1 数据采集

水烛、香菇草、梭鱼草和再力花是上海典型河道内的 4 种主要优势种群^[1],在 9—10 月份进入成熟期,生物量达到最大,对水环境的修复功能达到最佳^[27]。上海 9—10 月份气候条件适宜,光照充足,是采集光谱的最佳时期,故在此时段 (2019 年 9—10 月) 采集 4 种水生植物的光谱信息。图 1 为 4 种水生植物的实物图。叶片光谱是估算植被生化参数的重要依据,可与植物冠层光谱进行尺度转换,根据叶片光谱可实现植物种类识别^[28-29]。使用美国 ASD 公司的 HandHeld2 地物光谱仪采集 4 种水生植物的叶片光谱信息,该仪器可采集的光谱范围为 325~1075 nm,光谱分辨率小于 3 nm,采样间隔为 1.4 nm,采用独机工作模式。为了减小周围环境对数据采集的干扰,同时避免太阳光和其他光源的干扰,数据采集工作在封闭的室内完成,实验人员须穿着深色服装,并不得随意走动。将 HandHeld2 光谱仪和叶片夹相连,使用叶片夹对叶片样本进行固定,并采用内置的卤素灯进行照射。实验中每 10 min 进行一次白板测量校准和暗电流收集。共采集 3990 份样本数据,其中包括 927 份水烛样本、1064 份再力花样本、1069 份梭鱼草样本和 930 份香菇草样本。



图 1 4 种水生植物。(a) 梭鱼草; (b) 再力花; (c) 水烛; (d) 香菇草

Fig. 1 Four aquatic plants. (a) *Pontederia cordata* L.; (b) *Thalia dealbata*; (c) *Typha angustifolia* L.; (d) *Hydrocotyle vulgaris*

2.2 数据预处理

将采集的数据使用 ViewSpecPro 软件进行处理。由于接近量程,故去除 325~449 nm 范围的噪声,保留 450~1074 nm 范围内的有效数据。将保

留的有效数据使用 4 种不同的光谱分析法进行预处理,处理结果如图 2 所示。其中,图 2(a) 是原始光谱数据,图 2(b) 是采用一阶导数光谱法变换后的光谱数据,图 2(c) 是采用二阶导数光谱法变换

后的光谱数据,图 2(d)是采用一阶对数导数法变换后的光谱数据,图 2(e)是采用二阶对数导数法变换后的光谱数据。然后将转换后的光谱数据按

列排列,使用 MATLAB 中的灰度图片转换算法将其转换成 25×25 大小的特征矩阵,作为训练样本,如图 3 所示。

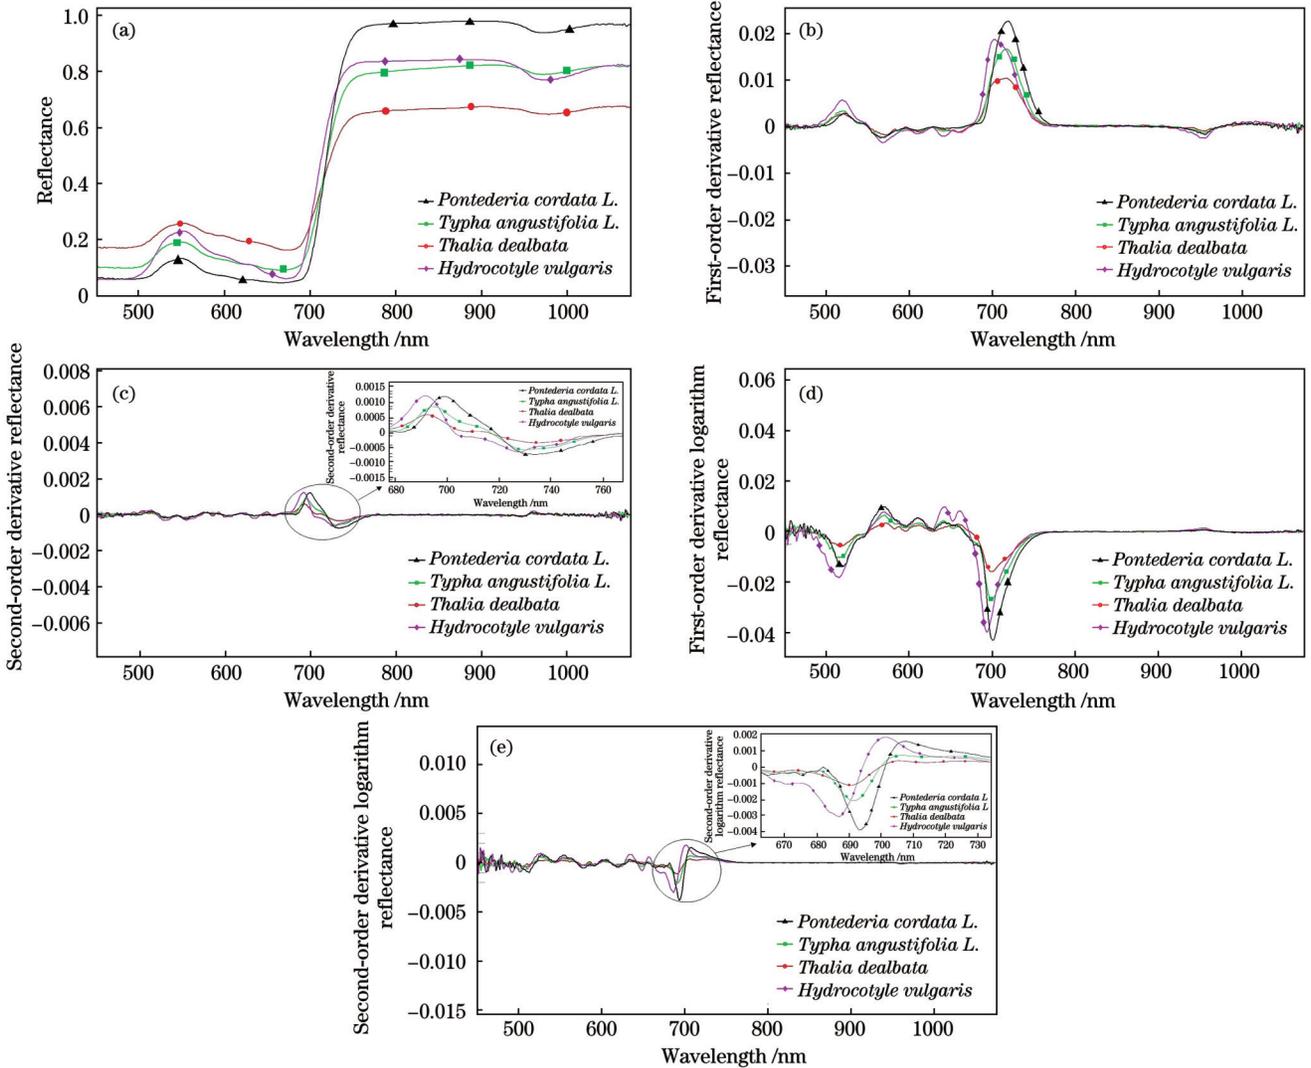


图 2 4 种水生植物的光谱曲线图。(a)原始光谱;(b)一阶导数光谱;(c)二阶导数光谱;(d)一阶对数导数光谱;(e)二阶对数导数光谱

Fig. 2 Spectral curves of 4 species of aquatic plants. (a) Original spectra; (b) first-order derivative spectra; (c) second-order derivative spectra; (d) first-order derivative logarithm spectra; (e) second-order derivative logarithm spectra

2.3 基于深度学习的水生植物光谱分类模型

AlexNet 模型是比较常用的深度学习模型,可实现深度特征的提取和分类功能,已被广泛应用于科学研究领域^[30-32]。本团队基于 AlexNet 网络模型建立了水生植物光谱分类模型,AlexNet 模型为 8 层卷积神经网络,包括 5 个卷积层和 3 个全连接层,最后采用 softmax 分类器对训练样本进行分类。近岸水生植物的光谱网络结构如图 4 所示。

在模型中,输入层的输入是一批大小为 25×25 的灰度矩阵 N 。第 1 层卷积层用 96 个大小为 11×11×3 的卷积核输入灰度矩阵 N 进行卷积计算,步长为 4。第 2 层卷积层将第 1 层卷积层的输出 $N^{(1)}$ 作为输入,然后使用 96 个大小为 5×5×96 的卷积核进行卷积

计算。第 3 层卷积层将第 2 层卷积层的输出 $N^{(2)}$ (经过池化后)作为输入,然后使用 384 个大小为 3×3×256 的卷积核进行卷积计算。第 4 层卷积层将第 3 层卷积层的输出 $N^{(3)}$ (经过池化后)作为输入,然后使用 384 个大小为 5×5×384 的卷积核进行卷积计算。第 5 层卷积层将第 4 层卷积层的输出 $N^{(4)}$ 作为输入,然后使用 256 个大小为 3×3×384 的卷积核进行卷积计算。第 6 层和第 7 层神经网络为全连接层,第 8 层神经网络为 softmax 分类层。卷积计算公式为

$$N^{(l)} = N^{(l-1)}k^{(l)} + b^{(l)}, \quad (1)$$

式中: l 为网络层数; $N^{(l-1)}$ 为第 $(l-1)$ 层卷积层的输出(亦即第 l 层卷积层的输入); $N^{(l)}$ 为第 l 层卷积层的输出; $k^{(l)}$ 为卷积核; $b^{(l)}$ 为偏置。

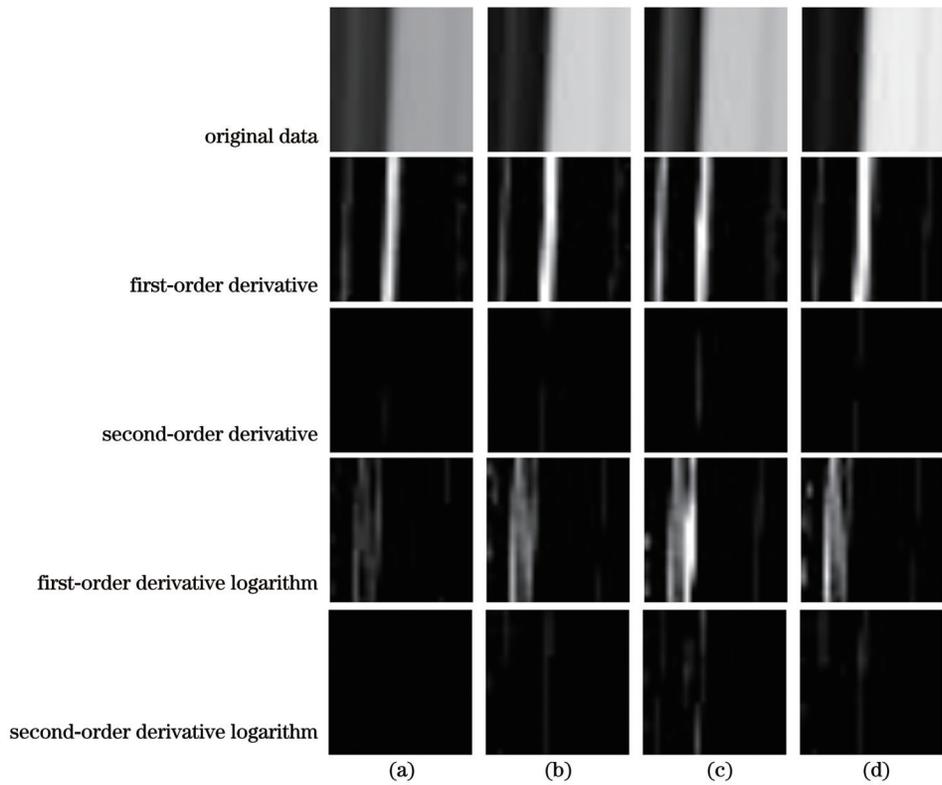


图 3 4 种水生植物的灰度图。(a)水烛;(b)梭鱼草;(c)香菇草;(d)再力花

Fig. 3 Gray scale images of 4 aquatic plants. (a) *Typha angustifolia* L.; (b) *Pontederia cordata* L.; (c) *Hydrocotyle vulgaris*; (d) *Thalia dealbata*

水生植物光谱识别模型采用的是非线性激活函数——ReLU 函数,其表达式为

$$f[N^{(l)}] = \max\{0, N^{(l)}\}, \quad (2)$$

式中: $N^{(l)}$ 为第 l 层卷积神经网络的输出。与 $f(x) = \tanh(x)$ 、 $f(x) = (1 + e^{-x})^{-1}$ 等传统的线性激活函数相比,ReLU 非线性激活函数的运算速度更快,训练错误

率更低。

本文的水生植物光谱识别模型采用 2 种策略来减小过拟合,分别是数据增强和 Dropout 机制。数据增强方式包括图像变换、水平翻转以及改变训练数据通道的强度等。经过对比实验,将模型中的 Dropout 参数设定为 0.5。

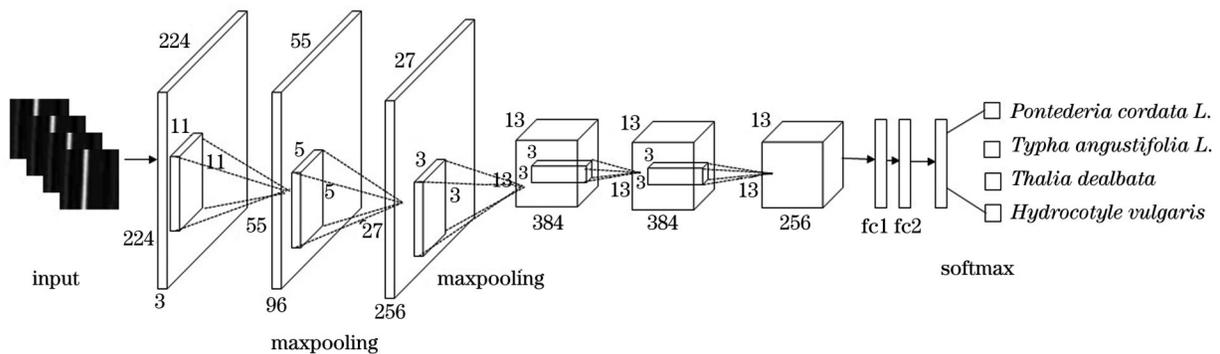


图 4 水生植物光谱分类模型

Fig. 4 Spectral identification model of aquatic plants

3 结果与分析

实验采用 PaddlePaddle 1.8.0 框架,软件编程环境为 Python 3.7,显卡为 Tesla V100,16 GB 显存, RAM 32 GB,处理器为 4 核 Intel(R) Xeon(R) Gold 6148。

为验证本文模型对近岸水生植物光谱的分类效

果,本团队设计了 3 个对比实验及 1 个特征光谱分析实验。实验一主要对比不同卷积神经网络的分类准确率和训练时间,确定最优网络结构;实验二主要研究样本数量对不同分类模型的影响,探究本文模型在小样本下的分类效果;实验三主要对比光谱预处理前后模型

实验四为特征光谱分析实验,对提取的近岸水生植物的敏感谱段进行分析,并将其与现有水生植物数据集的研究结果进行对比,以验证本文模型特征提取的有效性。

3.1 不同网络模型结构的对比

为验证 AlexNet 网络对水生植物光谱分类的效果,选取在 AlexNet 网络提出前后的两种经典网络

CNN3 和 VGG16 作为对比网络^[33]。实验所用数据集为 3990 条光谱曲线,将样本数据按照 8:2 分为训练集和测试集。将训练数据分别输入 CNN3 模型、本文模型和 VGG16 模型,迭代次数设置为 500,学习率为 0.0125,初始动量为 0.9, batch-size 为 64。本文模型、VGG16 模型和 CNN3 模型对近岸水生植物光谱数据的分类结果如表 1 所示。

表 1 不同模型下的光谱数据分类结果

Table 1 Spectral data classification under different models

Model	Training speed / (s · epoch ⁻¹)	Testing speed / (frame · s ⁻¹)	Accuracy / %
CNN3	5.56	0.030	85.06
VGG16	43.68	0.048	99.48
Our model	13.56	0.032	99.50

由表 1 可以看出:本文模型的分类准确率高于 VGG16 和 CNN3,达到了 99.50%;本文模型的训练速度和测试速度分别为 13.56 s/epoch 和 0.032 frame/s,比 VGG16 的训练速度和测试速度分别低 30.12 s/epoch 和 0.016 frame/s;虽然本文模型的训练速度和测试速度分别比 CNN3 模型高 8 s/epoch 和 0.002 frame/s,但是分类准确率比 CNN3 模型提高了 14.44 个百分点。这一实验结果表明,本文模型采用的 AlexNet 网络结构相比于 CNN3 和 VGG16 网络结构综合性能更优。

本文模型、VGG16 模型和 CNN3 模型在近岸水生植物光谱数据分类上的训练过程如图 5 所示,其中图 5(a)为 CNN3、VGG16、本文模型的训练准确率图,图 5(b)为 CNN3、VGG16 和本文模型的训练损失图。本文所用网络结构的训练准确率均高于 CNN3 和 VGG16,且训练损失值均小于 CNN3 和 VGG16。当训练轮数约为 200 时,本文网络开始收敛,而 VGG16 和 CNN3 分别在训练轮数约为 400 和 450 时才开始收敛。这表明本文网络结构能够快速收敛,在近岸水生植物的光谱分类上性能最优。

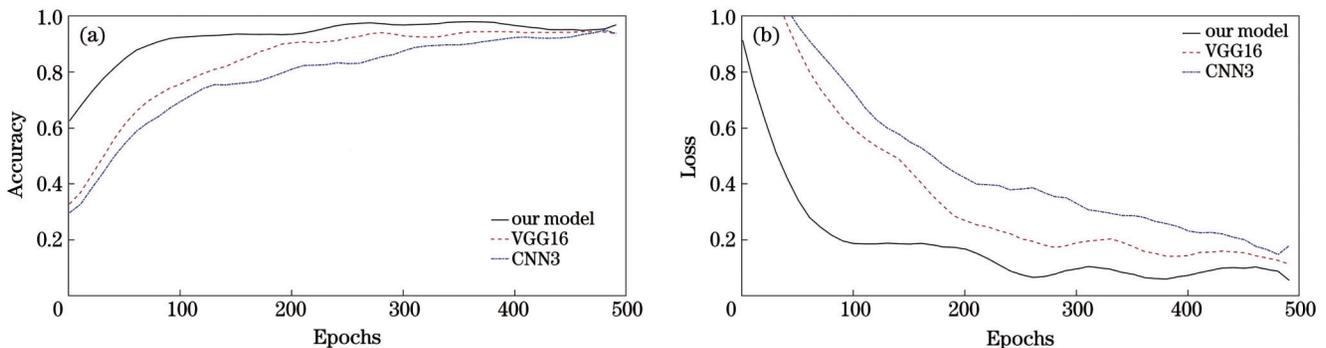


图 5 不同模型的训练过程图。(a)训练精度图;(b)训练损失图

Fig. 5 Training process diagrams of different models. (a) Training accuracy graph; (b) training loss graph

3.2 小样本对不同分类模型的影响

近岸水生植物的光谱数据需要人工实地测量,获取较为困难。为验证模型在小样本下的分类精度,分别随机选取样本数据集的 40%、60%、80% 作为训练集,测试集大小设置为 500,如表 2 所示。

表 2 不同训练集的划分

Table 2 Division of different training sets

Training data ratio / %	Training data quantity	Testing data quantity
40	1596	500
60	2394	500
80	3192	500

本文模型、VGG16 模型和 CNN3 模型在不同大小训练集下的分类准确率如表 3 所示。由表 3 可知,在相同大小的训练集下,本文模型的分类准确率均高于 VGG16 模型和 CNN3 模型,本文模型的最低分类准确率为 99.15% (40% 大小训练集),最高分类准确率为 99.50% (80% 大小训练集)。可见,本文模型在 40% 大小训练集下的分类准确率相比 80% 大小训练集仅降低了 0.35 个百分点。CNN3 在 40% 大小训练集下的分类准确率为 80.83%,相较于 80% 大小训练集下的 85.06% 分类精度降低了 4.23 个百分点。VGG16 在 40% 大小训练集下的分类精度为 97.70%,相较于 80% 大小训练集下的 99.48% 分类精度,降低了 1.78 个百分点。这一结果表明,本文模型在小样本下表现

表 3 不同训练集大小下的分类准确率

Table 3 Classification accuracy with different training set sizes

Model	Training data ratio / %	Accuracy / %
CNN3	40	80.83
	60	84.93
	80	85.06
VGG16	40	97.70
	60	98.74
	80	99.48
Our model	40	99.15
	60	99.44
	80	99.50

优秀,适用于水生植物光谱数据较少的情况。

表 4 样本数据预处理前后 3 种模型分类准确率对比

Table 4 Classification accuracy comparison of three kinds of models before and after sample data preprocessing

Model	Accuracy / %				
	Original data	First-order derivative	Second-order derivative	First-order derivative logarithm	Second-order derivative logarithm
CNN3	76.67	85.06	79.59	84.74	80.21
VGG16	96.45	99.48	97.99	98.41	97.20
Our model	97.80	99.50	98.56	99.10	98.95

对于经 4 种光谱分析法预处理后的样本数据,本文模型、VGG16 模型和 CNN3 模型的训练过程如图 6 所示,其中图 6(a)是 CNN3 模型的训练损失图,

3.3 光谱预处理对不同分类方法的影响

为减小光谱重叠谱带和背景干扰对分类结果的影响,本文使用一阶导数法、二阶导数法、一阶导数对数法和二阶导数对数法对原始光谱数据进行预处理,比较样本数据预处理前后 3 种模型(本文模型、CNN3 模型和 VGG16 模型)的分类准确率,结果如表 4 所示。

样本数据经不同方法预处理后,本文模型、CNN3 模型和 VGG16 模型分类准确率都有不同程度的提升,其中:样本数据经一阶导数法预处理后,CNN3 模型分类准确率由原始光谱数据的 76.67% 提高到 85.06%,提升最明显;VGG16 模型分类准确率由原始光谱数据的 96.45% 提高到 99.48%;本文模型分类准确率由原始光谱数据的 97.80% 提高到 99.50%。对于原始光谱数据和 4 种光谱分析法预处理后的光谱数据,本文模型分类准确率均高于其他 2 种模型。

图 6(b)是 VGG16 模型的训练损失图,图 6(c)是本文模型的训练损失图。由图 6 可知,CNN3 模型、VGG16 模型和本文模型对经一阶导数法预处理的样本数据的

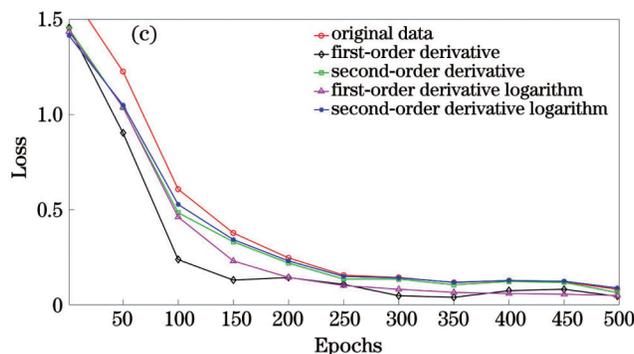
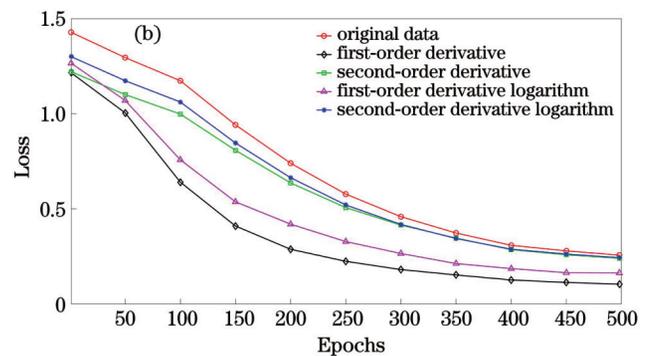
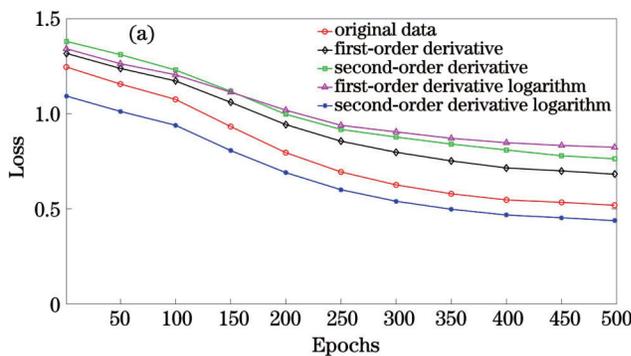


图 6 不同预处理方法下各模型的训练损失值。(a)CNN3 模型;(b)VGG16 模型;(c)本文模型

Fig. 6 Training loss value of each model under different preprocessing methods. (a) CNN3 model; (b) VGG16 model; (c) our model

训练损失值均小于对原始数据及经其他方法预处理的数据的训练损失值,且收敛速度也提高了。这一结果表明,一阶导数法可以有效减小重叠谱带和背景干扰的影响,提高模型的分类准确率。因此,本文所提网络结构结合一阶导数构建的近岸水生植物光谱数据分类模型可以实现 4 种近岸水生植物光谱的快速准确识别。

3.4 水生植物敏感光谱分析

已有研究表明,水生植物一般对近红外和红外波段敏感,因此,利用水生植物的近红外光谱信息可以有效识别出水生植物的种类^[17,34-36]。现有研究结果中提取的特征光谱谱带较宽,为提取更精确的近岸水生植物的特征光谱谱段,本团队利用 Grad-CAM 算法对建立的水生植物识别模型进行可视化研究。基于可视化中间特征图方法得到的最后 4 个卷积层输出的特征图如图 7 所示,从上到下分别为模型卷积层第 2 层、第 3 层、第 4 层、第 5 层的可视化特征图。图中颜色代表该区域特征的权重值,其中黄色最明亮,代表该区域的特征权重值越高。

基于可视化图像中的类激活的热力图得到的特征图如图 8 所示,其中不同的颜色代表特征信息不同的权重值,红色代表特征值的权重最大。

通过对中间特征图进行反卷积计算,提取类激活的热力图的红色区域,综合分析得到了 4 种近岸水生植物在 450~1074 nm 波段的主要分类敏感波段。其中:水烛的分类敏感波段有 7 个,分别是 456~461 nm、470~478 nm、714~720 nm、738~745 nm、881~891 nm、906~917 nm、930~941 nm;梭鱼草的分类敏

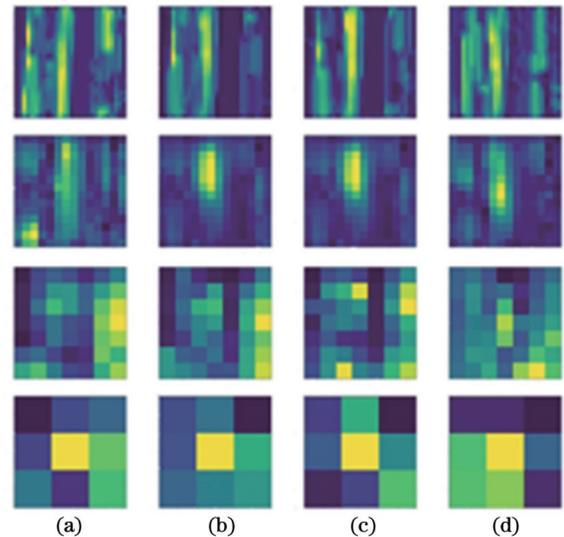


图 7 中间特征图。(a)水烛;(b)梭鱼草;(c)香菇草;(d)再力花
Fig. 7 Intermediate feature maps. (a) *Typha angustifolia* L.; (b) *Pontederia cordata* L.; (c) *Hydrocotyle vulgaris*; (d) *Thalia dealbata*

感波段有 2 个,分别是 456~461 nm 和 1055~1064 nm;香菇草的分类敏感波段有 8 个,分别是 663~668 nm、688~694 nm、714~719 nm、779~789 nm、803~813 nm、829~839 nm、846~851 nm、1052~1063 nm;再力花的分类敏感波段有 5 个,分别是 590~596 nm、794~799 nm、817~824 nm、842~849 nm、1064~1074 nm。这一结果与文献^[33-35]中的水生植物的敏感波段吻合,表明本文建立的水生植物光谱分类模型提取的 4 种水生植物的特征敏感波段较为准确,为 4 种水生植物遥感图像分类的特征谱段选择提供了重要参考。

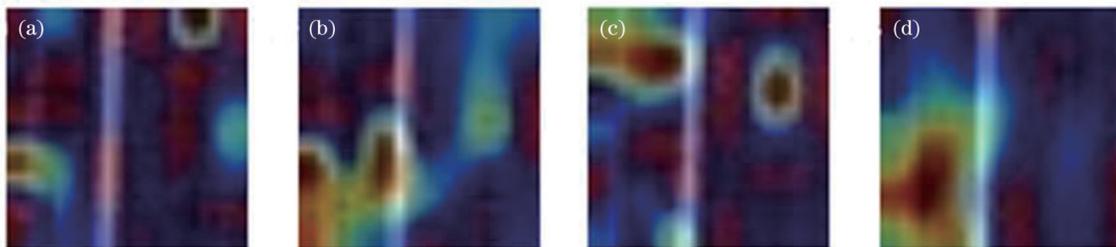


图 8 特征图。(a)水烛;(b)梭鱼草;(c)香菇草;(d)再力花
Fig. 8 Feature maps. (a) *Typha angustifolia* L.; (b) *Pontederia cordata* L.; (c) *Hydrocotyle vulgaris*; (d) *Thalia dealbata*

4 结 论

本文提出一种基于 AlexNet 网络的近岸水生植物光谱分类方法,并以上海典型河道内的 4 种主要近岸水生植物为研究对象,建立了能够准确识别近岸水生植物的深度学习模型。分析结果表明:1)本文模型提取的特征光谱与其他文献中提取的同类近岸水生植物的特征光谱谱带一致,表明本文模型对 4 种近岸水生植物分类正确且有效;2)本文模型能够全面有效地提取近岸水生植物的光谱特征,对样本的分类准确率达 99.50%,可满足对水烛、梭鱼草、香菇草、再力花 4

种水生植物生态监测的需要;3)通过对不同光谱预处理方法进行对比发现,一阶导数光谱预处理法可以有效去除重叠谱带和背景干扰,加快模型收敛速度,提高模型分类效果。一阶导数法与 AlexNet 网络结合的分类方法可以用于水烛、梭鱼草、香菇草和再力花这 4 种水生植物光谱的快速分类。

参 考 文 献

- [1] 吕钰煊,叶康,倪迪安,等.上海市水生植物资源调查及园林应用[J].应用技术学报,2019,19(4):355-362.
Lü Y H, Ye K, Ni D A, et al. Investigation and application of aquatic plant resources in Shanghai[J]. Journal of Technology,

- 2019, 19(4): 355-362.
- [2] 聂聪颖, 唐晶磊. 基于显著特征和全局特征融合的植物识别方法[J]. 计算机工程与设计, 2021, 42(4): 976-984.
- Nie C Y, Tang J L. Plant recognition method based on fusion of salient feature and global feature[J]. Computer Engineering and Design, 2021, 42(4): 976-984.
- [3] Zhou C L, Ge L M, Guo Y B, et al. A comprehensive comparison on current deep learning approaches for plant image classification [J]. Journal of Physics: Conference Series, 2021, 1873(1): 012002.
- [4] 原忠虎, 王维, 苏宝玲. 基于改进 VGGNet 模型的外来入侵植物叶片识别方法[J]. 计算机与现代化, 2021(9): 7-11.
- Yuan Z H, Wang W, Su B L. Leaf recognition method of invasive alien plants based on improved VGGNet model[J]. Computer and Modernization, 2021(9): 7-11.
- [5] 段欣荣, 曹见飞, 张宝雷, 等. 基于卷积神经网络和稳定性选择的农作物植被光谱分析方法[J]. 山东师范大学学报(自然科学版), 2020, 35(1): 100-107.
- Duan X R, Cao J F, Zhang B L, et al. Spectral analysis of crop vegetation based convolutional neural network and stability selection[J]. Journal of Shandong Normal University (Natural Science), 2020, 35(1): 100-107.
- [6] 王波, 柳小妮, 王洪伟, 等. 东祁连山高寒灌丛六种灌木植物的光谱特征分析[J]. 光谱学与光谱分析, 2019, 39(5): 1509-1516.
- Wang B, Liu X N, Wang H W, et al. Spectral characteristics analysis on six shrubs in different alpine brushlands of eastern Qilian mountains[J]. Spectroscopy and Spectral Analysis, 2019, 39(5): 1509-1516.
- [7] 潘建平, 涂文丽, 邓福江, 等. 顾及植被的复杂艰险地区多光谱遥感岩性识别[J]. 测绘科学, 2021, 46(8): 120-126.
- Pan J P, Tu W L, Deng F J, et al. Lithology identification of multi-spectral remote sensing in complex and difficult areas considering vegetation coverage[J]. Science of Surveying and Mapping, 2021, 46(8): 120-126.
- [8] 李楠, 孙德勇, 环宇, 等. 黄渤海浮游植物种群比吸收光谱的确定及其应用[J]. 光学学报, 2020, 40(6): 0601004.
- Li N, Sun D Y, Huan Y, et al. Determination and application of specific absorption spectra of phytoplankton species in Yellow Sea and Bohai Sea[J]. Acta Optica Sinica, 2020, 40(6): 0601004.
- [9] 谢欢, 陈争光, 张庆华. 基于近红外光谱的梗稻种子快速鉴别方法研究[J]. 光谱学与光谱分析, 2019, 39(10): 3267-3272.
- Xie H, Chen Z G, Zhang Q H. Rapid discrimination of japonica rice seeds based on near infrared spectroscopy[J]. Spectroscopy and Spectral Analysis, 2019, 39(10): 3267-3272.
- [10] 孙庆文, 温迪, 郭文凯, 等. 小花清风藤及其同属药用植物近红外光谱鉴定研究[J]. 中国现代中药, 2020, 22(5): 707-714.
- Sun Q W, Wen D, Guo W K, et al. Study on identification of *Sabia parviflora* and same genus medicinal plants by near infrared spectroscopy[J]. Modern Chinese Medicine, 2020, 22(5): 707-714.
- [11] Fan S X, Li C Y, Huang W Q, et al. Data fusion of two hyperspectral imaging systems with complementary spectral sensing ranges for blueberry bruising detection[J]. Sensors, 2018, 18(12): 4463.
- [12] 李秉璇, 周冰, 贺宣, 等. 针对高光谱图像的目标分类方法现状与展望[J]. 激光与红外, 2020, 50(3): 259-265.
- Li B X, Zhou B, He X, et al. Status and prospects of target classification methods based on hyperspectral images[J]. Laser & Infrared, 2020, 50(3): 259-265.
- [13] 李强, 曾曙光, 郑胜, 等. 基于机器视觉的陶瓷瓦表面裂纹检测算法[J]. 激光与光电子学进展, 2020, 57(8): 081004.
- Li Q, Zeng S G, Zheng S, et al. Machine vision based detection method for surface crack of ceramic tile[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081004.
- [14] 张立欣, 张楠楠, 张晓. 基于机器学习算法对苹果产地的判别分析[J]. 激光与光电子学进展, 2022, 59(4): 0430001.
- Zhang L X, Zhang N N, Zhang X. Discriminant analysis of apple origin based on machine learning algorithm[J]. Laser & Optoelectronics Progress, 2022, 59(4): 0430001.
- [15] 汪星, 宫兆宁, 井然, 等. 基于连续统去除法的水生植物提取及其时空变化分析: 以官厅水库库区为例[J]. 植物生态学报, 2018, 42(6): 640-652.
- Wang X, Gong Z N, Jing R, et al. Extraction of aquatic plants based on continuous removal method and analysis of its temporal and spatial changes: a case study of Guanting Reservoir[J]. Chinese Journal of Plant Ecology, 2018, 42(6): 640-652.
- [16] 张莹莹, 蔡晓斌, 宋辛辛, 等. 基于决策树的洪水水生植物遥感信息提取[J]. 湿地科学, 2018, 16(2): 213-222.
- Zhang Y Y, Cai X B, Song X X, et al. Remote sensing information extraction of hydrophyte in Honghu Lake based on decision tree[J]. Wetland Science, 2018, 16(2): 213-222.
- [17] Oyama Y, Matsushita B, Fukushima T. Distinguishing surface cyanobacterial blooms and aquatic macrophytes using Landsat/TM and ETM + shortwave infrared bands[J]. Remote Sensing of Environment, 2015, 157: 35-47.
- [18] Schmidt K S, Skidmore A K. Spectral discrimination of vegetation types in a coastal wetland[J]. Remote Sensing of Environment, 2003, 85(1): 92-108.
- [19] Luo J H, Li X C, Ma R H, et al. Applying remote sensing techniques to monitoring seasonal and interannual changes of aquatic vegetation in Taihu Lake, China[J]. Ecological Indicators, 2016, 60: 503-513.
- [20] Wang L, Dronova I, Gong P, et al. A new time series vegetation-water index of phenological-hydrological trait across species and functional types for Poyang Lake wetland ecosystem[J]. Remote Sensing of Environment, 2012, 125: 49-63.
- [21] 赵勇, 荣康, 谈爱玲. 基于一维卷积神经网络的雌激素粉末拉曼光谱定性分类[J]. 光谱学与光谱分析, 2019, 39(12): 3755-3760.
- Zhao Y, Rong K, Tan A L. Qualitative analysis method for Raman spectroscopy of estrogen based on one-dimensional convolutional neural network[J]. Spectroscopy and Spectral Analysis, 2019, 39(12): 3755-3760.
- [22] 于重重, 周兰, 王鑫, 等. 基于 CNN 神经网络的小麦不完善粒高光谱检测[J]. 食品科学, 2017, 38(24): 283-287.
- Yu C C, Zhou L, Wang X, et al. Hyperspectral detection of unsound kernels of wheat based on convolutional neural network [J]. Food Science, 2017, 38(24): 283-287.
- [23] 王强, 武凯, 王新宇, 等. 基于 X 射线和卷积神经网络的异物水饺识别[J]. 食品科学, 2019, 40(16): 314-320.
- Wang Q, Wu K, Wang X Y, et al. Recognition of dumplings with foreign body based on X-ray and convolutional neural network[J]. Food Science, 2019, 40(16): 314-320.
- [24] 郑宗生, 胡晨雨, 黄冬梅, 等. 基于迁移学习及气象卫星云图的台风等级分类研究[J]. 遥感技术与应用, 2020, 35(1): 202-210.
- Zheng Z S, Hu C Y, Huang D M, et al. Research on transfer learning methods for classification of typhoon cloud image[J]. Remote Sensing Technology and Application, 2020, 35(1): 202-210.
- [25] 孟庆龙, 张艳, 尚静. 高光谱成像结合 BP 网络无损检测李子的硬度[J]. 激光与红外, 2019, 49(8): 968-973.
- Meng Q L, Zhang Y, Shang J. Nondestructive detection on firmness of plums based on hyperspectral imaging and BP network [J]. Laser & Infrared, 2019, 49(8): 968-973.
- [26] 李佳瑞, 王继芬, 范琳媛, 等. 基于光谱和色谱数据碰撞融合策略的大麻油快速识别分类[J]. 激光与光电子学进展, 2022, 59(16): 1630004.
- Li J R, Wang J F, Fan L Y, et al. Rapid identification and classification of cannabis oil based on collision fusion strategy of spectral and chromatographic data[J]. Laser & Optoelectronics Progress, 2022, 59(16): 1630004.
- [27] 李锋民, 陈琳, 姜晓华, 等. 水质净化与生态修复的水生植物优选指标体系构建[J]. 生态环境学报, 2021, 30(12): 2411-2422.
- Li F M, Chen L, Jiang X H, et al. The construction of index system for selecting aquatic plant in water purification and ecological restoration[J]. Ecology and Environmental Sciences,

- 2021, 30(12): 2411-2422.
- [28] 于颖, 宋张亮, 范文义, 等. 植被冠层光谱和叶片光谱的尺度转换[J]. 武汉大学学报(信息科学版), 2018, 43(10): 1560-1565, 1573.
Yu Y, Song Z L, Fan W Y, et al. Scale conversion from canopy spectra to leaf spectra[J]. Geomatics and Information Science of Wuhan University, 2018, 43(10): 1560-1565, 1573.
- [29] 王京萌, 赵文吉, 郭道宇, 等. 优势水生植物光谱特征识别研究[J]. 安徽农业科学, 2012, 40(17): 9424-9426.
Wang J M, Zhao W J, Guo X Y, et al. Identification of the spectral characteristics of dominant aquatic plants[J]. Journal of Anhui Agricultural Sciences, 2012, 40(17): 9424-9426.
- [30] 党宇, 张继贤, 邓喀中, 等. 基于深度学习 AlexNet 的遥感影像地表覆盖分类评价研究[J]. 地球信息科学学报, 2017, 19(11): 1530-1537.
Dang Y, Zhang J X, Deng K Z, et al. Study on the evaluation of land cover classification using remote sensing images based on AlexNet[J]. Journal of Geo-Information Science, 2017, 19(11): 1530-1537.
- [31] Gu S S, Ding L, Yang Y, et al. A new deep learning method based on AlexNet model and SSD model for tennis ball recognition [C]//2017 IEEE 10th International Workshop on Computational Intelligence and Applications, November 11-12, 2017, Hiroshima, Japan. New York: IEEE Press, 2017: 159-164.
- [32] Alom M Z, Taha T, Yakopcic C, et al. The history began from AlexNet: a comprehensive survey on deep learning approaches [EB/OL]. (2018-03-03) [2021-02-05]. <https://arxiv.org/abs/1803.01164>.
- [33] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
Zhou F Y, Jin L P, Dong J. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [34] Villa P, Mousivand A, Bresciani M. Aquatic vegetation indices assessment through radiative transfer modeling and linear mixture simulation[J]. International Journal of Applied Earth Observation and Geoinformation, 2014, 30: 113-127.
- [35] 张翼然, 宫兆宁, 赵文吉. 水分环境梯度下野鸭湖湿地典型植物光谱特征分析[J]. 光谱学与光谱分析, 2012, 32(3): 743-748.
Zhang Y R, Gong Z N, Zhao W J. Typical plant spectral characteristics analysis in wild duck lake along water environment gradient[J]. Spectroscopy and Spectral Analysis, 2012, 32(3): 743-748.
- [36] 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.

Spectral Classification and Characteristic Spectral Analysis of Nearshore Aquatic Plants Based on AlexNet

Zheng Zongsheng, Liu Bei*, Lu Peng, Wang Zhenhua, Zou Guoliang, Zhao jiahui, Li Yunfei
School of Information, Shanghai Ocean University, Shanghai 201306, China

Abstract

Objective Aquatic plants can purify pollutants and inhibit algae growth. Therefore, obtaining accurate information on the number and growth status of aquatic plant species helps monitor the aquatic ecological environment. Spectral analysis, as a vital method for aquatic plant identification, has the characteristics of noncontact, fast, and pollution-free. However, because they are affected by the surrounding water environment, the characteristic spectral peaks of green aquatic plants are more challenging to distinguish than terrestrial plants. The ground spectral data have high dimensions and numerous overlapping bands and background interferences, and the characteristic spectrum is not obvious. The data are more challenging, and a few ground spectral datasets are suitable for deep learning. Currently, conventional machine learning classification methods cannot accurately and comprehensively extract deep features on small samples, resulting in unsatisfactory final classification results. Therefore, the deep learning algorithm and hyperspectral data are used to classify aquatic plants for the problems of many overlapping spectral bands, background interference, inconspicuous characteristic peaks, and less self-built aquatic plant spectral sample data.

Methods This study uses the first-order derivative method combined with the AlexNet network to classify and identify four nearshore aquatic plants. The classification accuracy and training speed of three convolutional neural networks (AlexNet, CNN3, and VGG16) were compared to verify the classification effect of our model on the nearshore aquatic plant spectrum and the AlexNet network was determined as the optimal network structure. Furthermore, the influence of the number of samples on different classification models was studied, and classification effect of three models under small samples was explored. The influence of spectral preprocessing on the model's classification effect was studied, and the sample data before and after preprocessing using four spectral preprocessing methods were compared. Finally, the Grad-CAM algorithm was used to study the classification model visually to extract the characteristic bands of four aquatic plants. The sensitive spectrum bands of nearshore aquatic plants were analyzed, extracted, and compared with the existing aquatic plant datasets. The results are compared to verify the effectiveness of the feature extraction of this study's model.

Results and Discussions The classification model based on the first-order derivative combined with the AlexNet network can realize the fast and accurate classification and identification of this study's four aquatic plants. Compared with the VGG16 and CNN3 networks, this study's model has the highest test accuracy of 99.50%. The model's training and testing speeds are 13.56 s/epoch and 0.032 frame/s, respectively, which are 30.12 s/epoch and 0.016 frame/s lower than those of VGG16. Although the model's training speed is 8 s/epoch higher than that of CNN3 and the testing speed is 0.002 frame/s higher, the classification accuracy is 14.44

percentage points higher than that of the CNN3 model. To verify the model's classification accuracy under small samples, 40%, 60%, and 80% of the sample dataset were randomly selected as the training set. The lowest classification accuracy of the model was 99.15%, higher than the classification accuracy of the CNN3 and VGG16 models. The influences of spectral overlapping bands and background interference on the classification results were reduced using four spectral preprocessing methods to process the sample data, and the classification accuracy of the three models before and after preprocessing was compared. The first-order derivative method improved the classification accuracy. The first-order derivative combined with the AlexNet network has the highest classification accuracy of 99.50%. The Grad-CAM algorithm was used to visualize the established aquatic plant identification model, and the classification-sensitive bands of four aquatic plants were analyzed, including seven classification sensitive bands for *Typha angustifolia* L., two classification sensitive bands for *Pontederia cordata* L., eight classification sensitive bands for *Hydrocotyle vulgaris*, and five classification sensitive bands for *Thalia dealbata*.

Conclusions This study proposed a spectral classification method of nearshore aquatic plants based on the first-order derivative combined with the AlexNet network. Taking the four primary nearshore aquatic plants in typical river channels in Shanghai as the research objects, a deep learning model capable of accurately identifying nearshore aquatic plants was established. The results showed that the characteristic spectrum extracted using this study's model correlates with the characteristic spectral bands of similar nearshore aquatic plants extracted in other studies, indicating that the model is correct and effective for classifying four nearshore aquatic plants. By comparing the classification effects before and after spectral preprocessing, it is found that the first-order derivative spectral preprocessing method can effectively remove overlapping spectral bands and background interference, increase the model's convergence speed, and improve the model classification effect. The classification method combined with the first-order derivative method and the AlexNet network is applied to rapidly classify the spectrum of four aquatic plants: *Typha angustifolia* L., *Pontederia cordata* L., *Hydrocotyle vulgaris*, and *Thalia dealbata*. It provides an essential reference for classifying and identifying these four aquatic plants under hyperspectral remote sensing.

Key words spectroscopy; nearshore aquatic plants; deep learning; spectral pretreatment; AlexNet network