

基于 GF-2 的江苏滨海湿地遥感

深度学习分类算法研究

游佩佩¹ 刘振波¹ 谢嘉伟² 徐军² 葛云健³ 吴璐瑶¹¹

(1. 南京信息工程大学 遥感与测绘工程学院, 江苏 南京 210044;

2. 南京信息工程大学 自动化学院, 江苏 南京 210044;

3. 南京信息工程大学 地理科学学院, 江苏 南京 210044)

【摘要】: 以江苏盐城滨海湿地为研究区, 基于高分二号(GF-2)高空间分辨率遥感影像, 应用VGG16_bN深度学习网络对研究区不同地物类别进行分类, 并与VGG16、SVM和BP神经网络分类结果进行对比, 综合评价分析分类结果精度与适用性。研究结果表明: 与其他分类算法结果相比, 基于深度学习VGG16_bN网络的影像分类精度相对最高, 总体分类精度达99.32%, Kappa系数0.99, 均显著高于其它分类算法精度。此外, 通过局部可视化分析, VGG16_bN网络算法分类结果可有效保持大面积同类地物的区域一致性, 有效避免“椒盐”噪声, 对道路、河流等线状地物的连续性和边界提取较为完整和清晰。

【关键词】: 高分二号 湿地植被分类 深度学习 VGG16BN

【中图分类号】: TP79;TP181 **【文献标识码】:** A **【文章编号】:** 1004-8227(2021)07-1659-11

湿地是地球表面最重要的生态系统之一, 有“地球之肾”之称, 其中滨海湿地为位于海陆交错地带的一种湿地类型, 兼具水生生态系统和陆地生态系统的特点, 其丰富的自然资源可以为生物提供栖息地与丰富的水源, 具有涵养水源、防止海岸带侵蚀、降解污染物、调节气候等重要作用^[1]。1982年, 互花米草因其能够促淤造陆、防风固堤等优点被引进盐城滨海湿地^[2], 区内原有野生珍禽丹顶鹤等喜在碱蓬中觅食栖息, 但互花米草根系发达, 适应力强, 被引种后迅速繁殖扩张, 侵占碱蓬等原生植被生长空间, 对原生植被的自然正常演替及生物多样性构成极大威胁, 2003年被列为入侵物种。2019年7月5日, 江苏盐城滨海湿地申遗成功, 成为全球第二个潮间带湿地遗产。在这种背景下, 快速准确地获取湿地植被信息, 掌握不同湿地覆被面积变化状况, 对保护湿地生态系统和有效开发湿地生态资源具有十分重要的意义^[3]。滨海湿地面积范围广, 内部不可及, 传统人工地面调查耗时耗力, 难以满足及时获取湿地覆被信息的需求, 而遥感技术具有观测面积大、周期短以及成本低等优点, 对动态提取湿地信息具有极大优势。

目前, 湿地信息提取的难点是对湿地植被覆被类型的有效识别, 其方法也成为湿地遥感信息解译的热点^[4]。经典的湿地覆被

¹**作者简介:** 游佩佩(1994~), 女, 硕士研究生, 主要研究方向为资源环境遥感研究. E-mail:398805972@qq.com
刘振波 E-mail:ZBLiu@nuist.edu.cn

基金项目: 国家自然科学基金项目(U1809205, 61771249, 91959207, 81871352); 江苏省自然科学基金项目(BK20181411); 江苏省“青蓝工程”资助; 江苏省大学生实践创新训练计划(201810300244)

信息遥感解译方法主要有基于像元的监督分类法和面向对象分类法，大多基于约30m空间分辨率的陆地资源卫星或雷达影像^[5~7]。近年来随着人工智能的蓬勃发展，基于机器学习的遥感影像解译算法逐渐兴起，如随机森林(Random Forest, RF)算法、BP神经网络(Back Propagation Neural Network)和支持向量机(Support Vector Machine, SVM)等，这些算法逐渐被应用到遥感影像信息解译研究，有效提高了影像分类的精度，如Lin等^[8]分别利用最小距离法和改进后的SVM算法对崇明岛湿地Landsat影像进行信息提取，结果表明改进后的SVM分类算法总体精度较最小距离法高14.90%；Ke等^[9]使用BP神经网络对南京江心洲湿地公园的影像解译总体精度达93%。近年来随着高空间分辨率遥感卫星技术的迅速发展，卫星遥感影像对地物特征的描述更加精细化，这一方面为影像信息解译精度的进一步提高提供了可能，另一方面也对遥感信息解译的算法提出了新的挑战，而深度学习网络模型的出现，更是为高空间分辨率遥感影像的自动化精细解译提供了方向，如卷积神经网络(Convolutional Neural Network, CNN)就是一种能够有效学习影像空间特征的网络，具有很大的泛化能力，其中VGG16是卷积神经网络(CNN)中的一种经典模型，已有效应用于医学影像信息解译^[10]、农作物生长监测^[11]、城市目标检测^[12, 13]。

近年来，我国的高分系列卫星陆续发射升空，其中2014年8月发射入轨的高分二号(GF-2)卫星是我国自主研制的首颗空间分辨率优于1米的民用光学遥感卫星，搭载有两台高分辨率1米全色、4米多光谱相机，具备亚米级空间分辨率能力，已广泛应用于土地利用调查、矿产资源勘查以及森林资源调查等研究应用^[14]。江苏盐城滨海湿地珍禽国家级自然保护区核心区面积较小，相较于传统的陆地资源卫星数据，分辨率更高的GF-2影像所表达的植被信息更为丰富，因此本研究以保护区核心区为研究样区，基于GF-2高空间分辨率遥感影像，利用深度学习VGG16_BN模型算法对影像进行信息分类提取，分析验证深度学习算法对滨海湿地信息解译的应用能力及其适用性，为研究区植被变化监测和生态保护提供决策支持。

1 研究区概况

研究区位于江苏省盐城滨海湿地珍禽国家级自然保护区核心区(119° 53' 45" E ~ 121° 18' 12" E, 32° 48' 47" N ~ 34° 29' 28" N)，保护区主要保护丹顶鹤等珍禽及沿海湿地生态系统，气候为亚热带季风气候，核心区植被生态系统基本处于原始状态，植被主要分布有互花米草、芦苇、盐地碱蓬等滨海湿地植物。

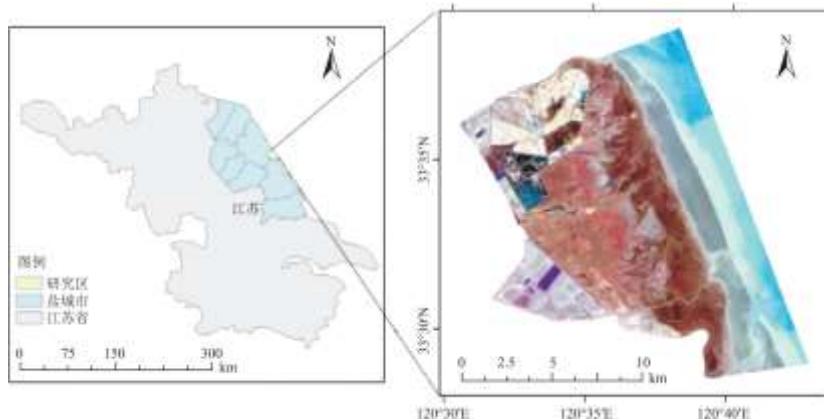


图1 研究区位置及GF-2遥感影像(2015年4月11日)

2 数据预处理及研究方法

2.1 遥感影像及预处理

2.1.1 高分二号卫星遥感影像及预处理

本研究选用研究区 2 期共 5 景已正射校正后的高分二号遥感影像，成像时间分别为 2015 年 4 月 11 日(3 景)和 2017 年 9 月 14 日(2 景)，云量均低于 10%。

首先利用 ENVI5.3 软件对高分二号遥感影像多光谱数据进行辐射定标和大气校正。随后对全色波段进行相对辐射校正，基于 Radiometric Calibration 辐射定标工具将全色数据定标为大气表观反射率，同时将尺度(Scale Factor)扩大 1000 倍，再利用 Image Registration Workflow 工具以全色波段为基准对预处理后的多光谱波段进行配准；然后使用 Gram-Schmidt Pan Sharpening 工具将全色波段与多光谱波段进行融合，并将各时期融合后影像通过 Seamless Mosaic 工具镶嵌拼接影像，最后将研究区边界矢量导入，并进行影像裁切。

为充分利用遥感数据光谱信息，基于植被光谱特性及光谱指数物理意义，利用 GF-2 的绿色波段、红色波段和近红外波段 3 个波段反射率进行特征提取，增加 6 个多光谱数据常用且对 GF-2 波段均适用的植被指数特征层，具体新增特征波段见表 1。

表 1 特征波段表

特征名称	说明	计算公式
NDVI	归一化植被指数	$NDVI = (\rho_{NIR} - \rho_{Red}) / (\rho_{NIR} + \rho_{Red})^{[15]} \quad (1)$
GNDVI	绿色归一化植被指数	$GNDVI = (\rho_{NIR} - \rho_{Green}) / (\rho_{NIR} + \rho_{Green})^{[16]} \quad (2)$
DVI	差值植被指数	$DVI = \rho_{NIR} - \rho_{Red}^{[16]} \quad (3)$
RVI	比值植被指数	$RVI = \rho_{NIR} / \rho_{Red}^{[16]} \quad (4)$
SAVI	土壤调整植被指数	$SAVI = (\rho_{NIR} - \rho_{Red}) / 1.5(\rho_{NIR} + \rho_{Red} + 0.5)^{[17]} \quad (5)$
OSAVI	优化土壤调整植被指数	$OSAVI = (\rho_{NIR} - \rho_{Red}) / 1.16(\rho_{NIR} + \rho_{Red} + 0.16)^{[17]} \quad (6)$

2. 1. 2 研究区湿地分类规则

基于研究区滨海湿地区域特点，将研究区湿地类型分为 3 大类：人工湿地、自然湿地和非湿地^[18]。自然湿地包括：芦苇、互花米草、碱蓬、无植被滩涂，人工湿地包括坑塘，非湿地包括道路、干涸坑塘等(统称为其它类)。另因图像分类需要，增加海水类别。构建的研究区分类系统见表 2。

表 2 研究区分类系统

一级分类	二级分类	三级分类
自然湿地	盐生植被用地	芦苇
		互花米草
		碱蓬
	非植被	无植被滩涂

人工湿地	非植被	坑塘
非湿地	其它	道路
		干涸坑塘
海水	海水	海水

2.1.3 训练与验证样本的选取

训练与验证样本点信息均来源于实地考察，设计野外调查路线，通过 $100\text{m} \times 100\text{m}$ 的样方进行地物类型实地勘测，现场 GPS 定位样方中心坐标同时记录样方湿地类型。借助 ENVI5.3 感兴趣区工具，随机选取样本集的 70% 作为训练样本集，通过人工标注的方法将研究区地物分为 8 类（背景也算作一类），将训练样本点光谱信息与其对应的地理坐标、影像行列号位置信息导出得到训练样本总集。剩余 30% 样本点作为验证样本集，具体训练与验证样本点位置见图 2（2017 年影像训练样本点位置与 2015 年相同，故以 2015 年为例）。

因以 $100\text{m} \times 100\text{m}$ 样方法进行实地勘测，故每一个样本点所占像元数为 10000 个。本研究在进行 VGG16_BN 及 VGG16 网络模型的训练时，先在训练样本总集中每类（共 8 类）随机选取 5000 个样本像元点，以选取的样本像元点为中心取 40×40 的 patch，共得 40000 张 $40 \times 40 \times 10$ 的多光谱多特征高空间分辨率数据集，输入模型进行训练。

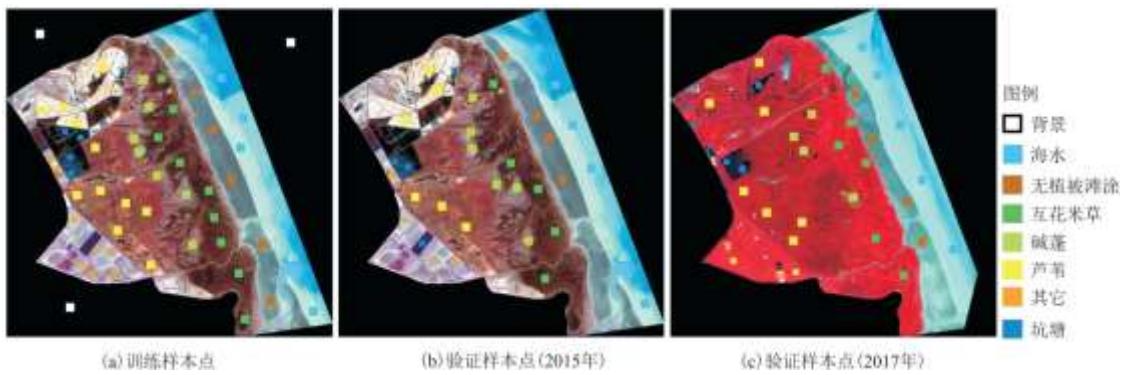


图 2 训练样本与验证样本点位置图

2.2 VGG16_BN 算法介绍

VGG16 网络是牛津大学 Visual Geometry Group Karon Simonyan 和 Andrew Zisserman 一起研发的深度卷积神经网络^[19]，“16”表示除池化层以外，网络由 13 个卷积层和 3 个高维全连接层组成^[20]。而 VGG_BN 模型是指在 VGG16 网络中每层卷积层之后加入一层 BN 层，用于改善 VGG16 网络性能的模型。

2.2.1 卷积神经网络 (Convolutional Neural Network, CNN)

卷积神经网络是一个多层次感知器，每一层（即特征层）由多个二维平面组成，而每个二维平面又由多个神经元构成。整个 CNN 模型由输入层、卷积层、池化层、全连接层以及输出层构成^[21]。CNN 的主要特点有两个：局部连接、权值共享。CNN 通过局部连接和权值共享减少网络的参数与计算量，基于深层网络将局部信息通过全连接层综合特征得到影像全局信息。

(1) 卷积层 (Convolutions Layer)

卷积层的目的是对影像进行特征提取。卷积层由若干个卷积核构成，卷积核的个数决定了输出特征的层数，同个层级的特征层数与卷积核是一一对应的，都等于上一层的输出通道数。

(2) 感受野 (Receptive Field)

在 CNN 中，感受野表示卷积神经网络每一次输出的特征图上像元点在输入图像上所映射区域的大小。

(3) 池化层 (Pooling Layer)

池化层是下采样层中的一种类型，在 CNN 中池化层一般在卷积层之后，池化层目的是减小特征图层尺寸，简化网络计算复杂度，同时进行特征压缩，提取主要特征，从而减少神经网络的计算量和参数。常见的池化操作有最大池化 (MaxPooling) 和平均池化 (MeanPooling) 操作。最大池化能够提取上层特征中的明显特征，尤其是纹理结构特征，而平均池化能够更好的保留影像整体数据特征，尤其是背景信息。

(4) 全连接层 (Fully Connected Layers)

全连接层的每一个结点都与上层的所有结点相连，从而综合前层网络提取到的特征，全连接层能够将所有二维特征图拉伸成为一维特征。

(5) 批归一化层 (Batch Normalization Layers)

批归一化层 (BN 层) 本质是一个归一化网络层，可加在 CNN 中，用于批数据的归一化。CNN 中加入 BN 层可加快网络训练速度，提高网络泛化能力，降低网络过拟合风险^[22]。

2.2.2 VGG16_BN 模型

VGG16_BN 模型网络使用 3×3 的卷积核以及 2×2 的最大池化核，将网络卷积层的概念升级成为卷积块，卷积块由 2~3 个卷积层构成，通过反复堆叠卷积层与池化层搭建模型，使模型学习能力更强。在每一个卷积层之后都加入一层 BN 层加快模型训练速度，提高网络泛化能力，最后通过全连接层将局部特征组装成全局特征，其中，在卷积层和全连接层中引入激活函数将线性感知器转换为非线性神经元，本研究所使用的为 ReLU 激活函数：

损失函数是用来衡量网络输出与样本标记之间的误差的一种函数。本研究使用交叉熵 (Cross Entropy) 损失函数，交叉熵描述的是两个概率分布之间的距离，即通过概率分布 q 来表达概率分布 p 的困难程度， p 代表正确数值， q 代表预测数值，当两数值越接近即交叉熵越小，当交叉熵达到最小值时分类器为最优，具体公式如下：

当损失函数值达到预期值训练完毕，使用 softmax 分类器进行分类并输出。具体 VGG16_BN 网络架构如图 3。

2.3 研究设计

本研究基于 VGG16_BN 模型，分别对 2015 年及 2017 年 GF-2 影像进行分类，为验证加入 BN 层的 VGG16 模型合理性，将基于 VGG16_BN 的 2015 年分类结果分别与未加入 BN 层的 VGG16、支持向量机 (SVM) 和 BP 神经网络分类结果进行精度评价对比，并对

基于 VGG16_BN 的 2017 年分类结果进行精度评价，探讨 VGG16_BN 模型对湿地区域高空间分辨率遥感影像信息解译的适用性。

2.4 运行环境

本研究在 Ubuntu16.04 操作系统内完成，具体环境为硬盘 1T, GPU:Nvidia1080Ti, CPU:IntelE5-2630V4, 内存 128G。VGG16 网络在 Python3.7 中实现，深度学习框架为 Pytorch。

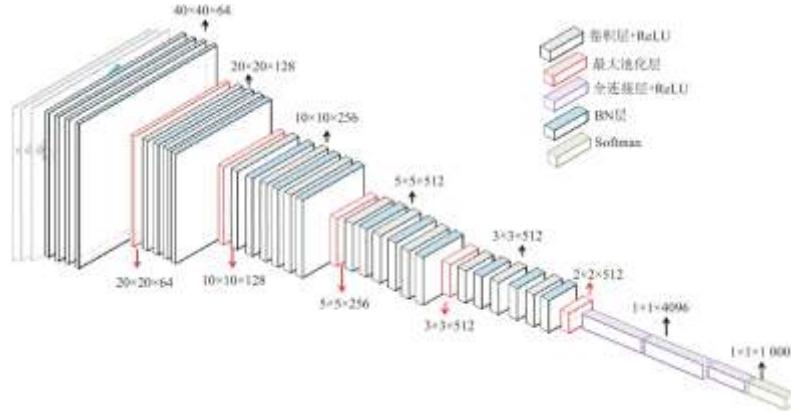


图 3 VGG16_BN 卷积神经网络架构

3 结果与讨论

3.1 总体分类精度评价

基于 2.1.3 所述样本训练流程，利用 VGG16_BN 与 VGG16 网络模型首先对 2015 年样本点进行训练，图 4 为两个模型训练时迭代轮数(epoch)与准确率(acc)之间的趋势图，每一个 epoch 包含 1000 次训练。可以发现两个模型初始训练精度相同，但在第 27 个 epoch 以后 VGG16_BN 模型逐渐收敛且性能趋于稳定，且在第 31 个 epoch 的时候，模型的性能在验证集上能取得峰值 0.95；而未加入 BN 层的传统 VGG16 模型在第 28 个 epoch 以后才开始逐渐收敛，且 acc 在第 38 个 epoch 才达到峰值 0.95，较 VGG16_BN 模型晚 7 个 epoch。

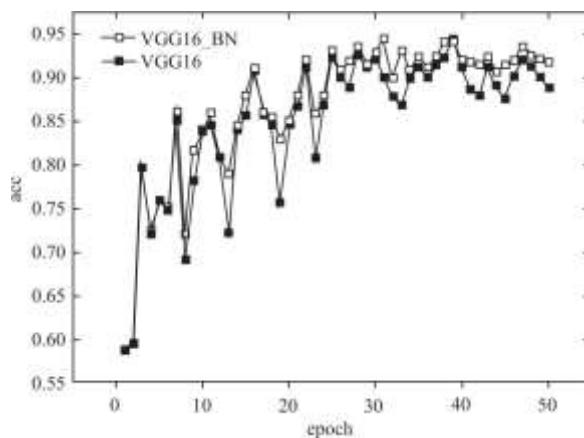


图 4 VGG16_BN 与 VGG16 epoch 与 acc 变化趋势图

经对比可知，加入 BN 层后 VGG16 模型的收敛速度明显加快，此外 VGG16_BN 模型的收敛相对更为稳定。

将 VGG16_BN、VGG16 网络模型分类结果与 SVM 和 BP 神经网络结果进行对比，生成研究区 4 种算法影像分类结果图(图 5)，为使各类验证样本数量级相同，在图 2(b)中每类(共 7 类)选取 40000 个像元点作为验证样本，借助 ENVI5.3 软件分别统计 4 种算法的总体分类精度与 Kappa 系数(图 6)。

由图 5 可见，4 种算法均能较好的实现研究区不同地物及不同植被类型的分类，研究区植被类型总体上呈现由沿海到内陆的条带状分布，互花米草主要分布于沿海岸带区域，丹顶鹤较为适宜生活的碱蓬主要分布于保护区的中间区域，且相对于互花米草和芦苇植被类型其分布面积相对较少。由图 6 中可知 4 种分类方法中 VGG16_BN 的分类精度最高，其余 3 种方法分类精度依次下降。VGG16_BN 总体分类精度达到 99.32%，Kappa 系数为 0.99，较 VGG16 精度提高 0.59%，BP 神经网络分类精度相对最低，总体分类精度为 90.87%。

为验证 VGG16_BN 网络对高空间分辨率遥感影像的信息解译适用性，本研究基于 VGG16_BN 模型对同区域 2017 年 GF-2 遥感影像进行分类，分类结果见图 7。由图 7 可知，基于 VGG16_BN 模型的 2017 年 GF-2 影像分类结果达到了同样理想的分类效果，总体分类精度和 Kappa 系数分别为 98.83%、0.99，表明 VGG16_BN 网络对提取不同时期 GF-2 的湿地主要地物类型信息具有较好适用性，泛化能力较强。

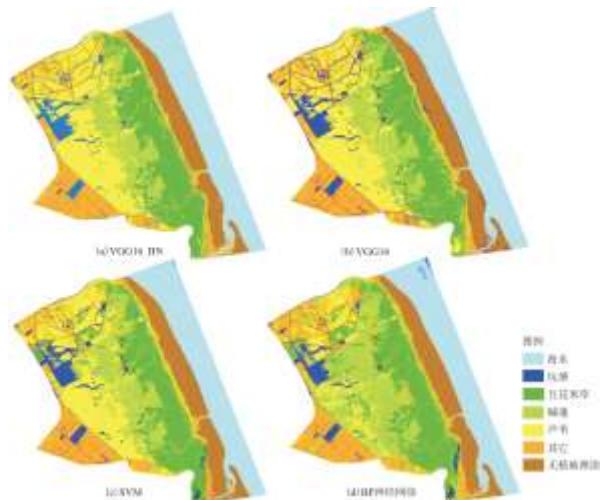


图 5 4 种分类方法成果图(2015 年)

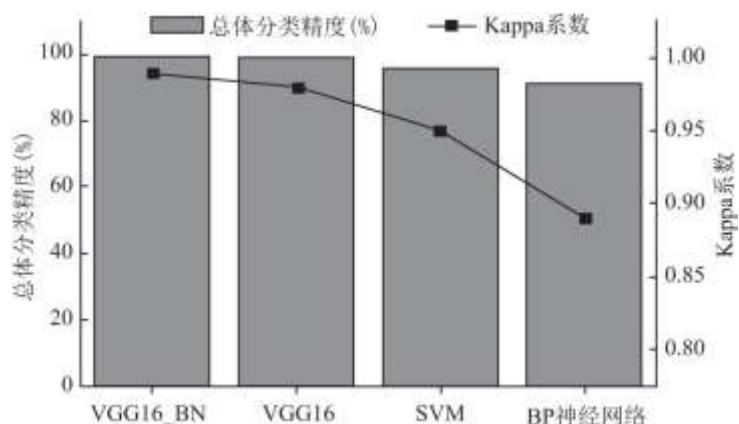


图 6 总体分类精度与 Kappa 系数(2015 年)

3.2 不同地物类别分类精度评价

基于上述验证样本，构建 2015 年不同地物类别的分类混淆矩阵(表 3~6)。根据 4 种分类结果混淆矩阵表可见，VGG16_BN 对互花米草的分类能力最好，其分类精度达到了 99.45%，较 VGG16 网络、SVM 和 BP 神经网络分别提高 0.16%、0.25% 和 0.21%。对于碱蓬植被，VGG16_BN 的分类精度也最高，为 96.89%；VGG16 网络精度位于其次，为 95.83%；其余两种分类方法对碱蓬的漏分误差均高于 25.25%。芦苇植被类型 VGG16_BN 算法分类结果也是最优，分类精度达 99.33%；其次为 VGG16 算法，其精度为 98.24%；BP 神经网络对芦苇的分辨能力相对较差，其分类精度比其余三种分类方法均低约 30%，漏分误差达 32.16%。

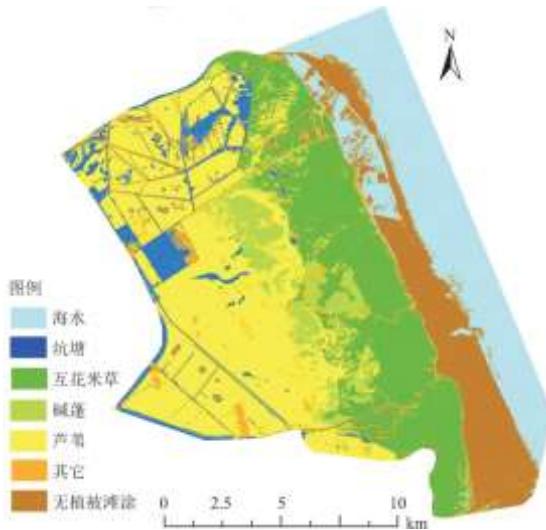


图 7 基于 VGG16_BN 的 2017 年分类结果图

表 3 基于 VGG16_BN 的混淆矩阵

	海水	坑塘	互花米草	碱蓬	芦苇	其它	无植被滩涂	总计
海水	40000	0	0	0	0	0	0	40000
坑塘	0	39976	0	0	0	138	0	40114
互花米草	0	0	39779	0	0	0	0	39779
碱蓬	0	0	0	38754	230	0	0	38984
芦苇	0	0	221	266	39731	0	0	40218
其它	0	24	0	980	39	39862	0	40905
无植被滩涂	0	0	0	0	0	0	40000	40000
总计	40000	40000	40000	40000	40000	40000	40000	280000
用户者精度(%)	100	99.66	100	99.41	98.79	97.45	100	-

生产者精度(%)	100	99.94	99.45	96.89	99.33	99.66	100	-
----------	-----	-------	-------	-------	-------	-------	-----	---

表 4 基于 VGG16 的混淆矩阵

	海水	坑塘	互花米草	碱蓬	芦苇	其它	无植被滩涂	总计
海水	40000	0	0	0	0	0	0	40000
坑塘	0	39948	0	0	0	680	0	40628
互花米草	0	0	39716	0	0	0	0	39716
碱蓬	0	0	0	38332	666	0	0	38998
芦苇	0	0	284	266	39295	0	0	39845
其它	0	52	0	1402	39	39320	0	40813
无植被滩涂	0	0	0	0	0	0	40000	40000
总计	40000	40000	40000	40000	40000	40000	40000	280000
用户者精度(%)	100	98.33	100	98.29	98.62	96.34	100	-
生产者精度(%)	100	99.87	99.29	95.83	98.24	98.30	100	-

表 5 基于 SVM 分类的混淆矩阵

	海水	坑塘	互花米草	碱蓬	芦苇	其它	无植被滩涂	总计
海水	39974	6	0	0	0	0	0	39980
坑塘	22	39990	0	0	0	0	0	40012
互花米草	0	0	39678	143	287	2	0	40110
碱蓬	0	0	16	29901	456	13	0	30386
芦苇	0	0	284	235	39236	320	0	40075
其它	4	4	22	9721	21	39664	0	49436
无植被滩涂	0	0	0	0	0	1	40000	40001
总计	40000	40000	40000	40000	40000	40000	40000	280000
用户者精度(%)	99.98	99.95	98.92	98.40	97.91	80.23	100	-
生产者精度(%)	99.94	99.98	99.20	74.75	98.09	99.16	100	-

表 6 基于 BP 神经网络的混淆矩阵

	海水	坑塘	互花米草	碱蓬	芦苇	其它	无植被滩涂	总计
海水	39950	269	0	0	0	0	0	40219
坑塘	49	39429	0	0	0	0	0	39478
互花米草	0	0	39697	119	2448	0	0	42264
碱蓬	0	0	231	28432	9084	120	0	37867
芦苇	0	12	71	13	27136	73	0	27305
其它	0	24	0	11367	1332	39805	0	52528
无植被滩涂	1	266	0	69	0	2	40000	40338
总计	40000	40000	40000	40000	40000	40000	40000	1400000
用户者精度(%)	99.33	99.88	93.93	75.08	99.38	75.78	99.16	-
生产者精度(%)	99.88	98.57	99.24	71.08	67.84	99.51	100	-

此外, VGG16_BN 和 VGG16 网络对海水的分辨能力也最好, 分类精度为 100%; SVM 和 BP 神经网络算法结果中均存在海水像元错分为坑塘的情况。

3.3 局部可视化分类结果分析

利用高分影像空间分辨率较高的优势, 采用局部区域可视化的方法对 2015 年的不同算法地物分类结果进行局部可视化分析(图 8)。由图 8 可见, 海水和坑塘的像元光谱较易产生混淆, 在海水区域 VGG16_BN 与 VGG16 网络分类效果较好, 没有错分像元, 其他 2 种分类结果中都存在较为明显的海水像元错分为坑塘现象。在坑塘区域 VGG16 网络表现稍逊色于 VGG16_BN 网络, 有少部分坑塘像元错分为海水像元; 而 BP 神经网络对坑塘的提取能力最差, 将坑塘区域大面积的错分为了无植被滩涂与海水类型。

在互花米草、碱蓬和芦苇区域, VGG16_BN 与 VGG16 的提取能力最好, 这两种算法对大面积互花米草、碱蓬和芦苇等植被区域的分类结果较为完整, 几乎没有错分像元存在, 较好保持了同类型地物像元区域性、对象性以及整体性。这是由于 SVM 和 BP 神经网络为基于像元的分类算法, 未考虑相邻像元间的空间特征信息, 而 VGG16_BN 与 VGG16 网络训练时采取以样本点为中心的 40×40 的 patch 方法, 这种训练方法可以保证网络在训练单个像元特征的同时也将样本点周围点的特征作为学习内容辅助判断, 卷积神经网络其特有的卷积层和池化层能够局部提取影像特征, 全连接层能够将局部特征整合成全局特征, 故 VGG16_BN 与 VGG16 算法对保持一些大面积同类地物的整体性分类结果较好, 可以消除传统影像分类会产生的“椒盐”噪声。可见 VGG16_BN 和 VGG16 网络具有更好的局部至全局泛化学习能力, 故其分类结果更优。

道路局部图中, SVM 与 BP 神经网络结果中普遍存在“椒盐”现象, 分类结果较为零碎, VGG16_BN 与 VGG16 网络分类结果中道路与河流规整性保持的较好, 边界清晰, 无“噪声”像元, 此外, 与实际影像对比, VGG16_BN 提取的河流边界与形状较 VGG16 更为完整且连续。

由上述分析,VGG16_BN 能够在训练次数少于 VGG16 的情况下达到与 VGG16 相同甚至超过 VGG16 的分类效果,这说明 VGG16_BN

模型能够快速高效学习像元的空间几何信息，将具有相同纹理特征的像元组成一个对象，同时能够有效保证地物的纹理特征，易于湿地覆被类型的动态监测。

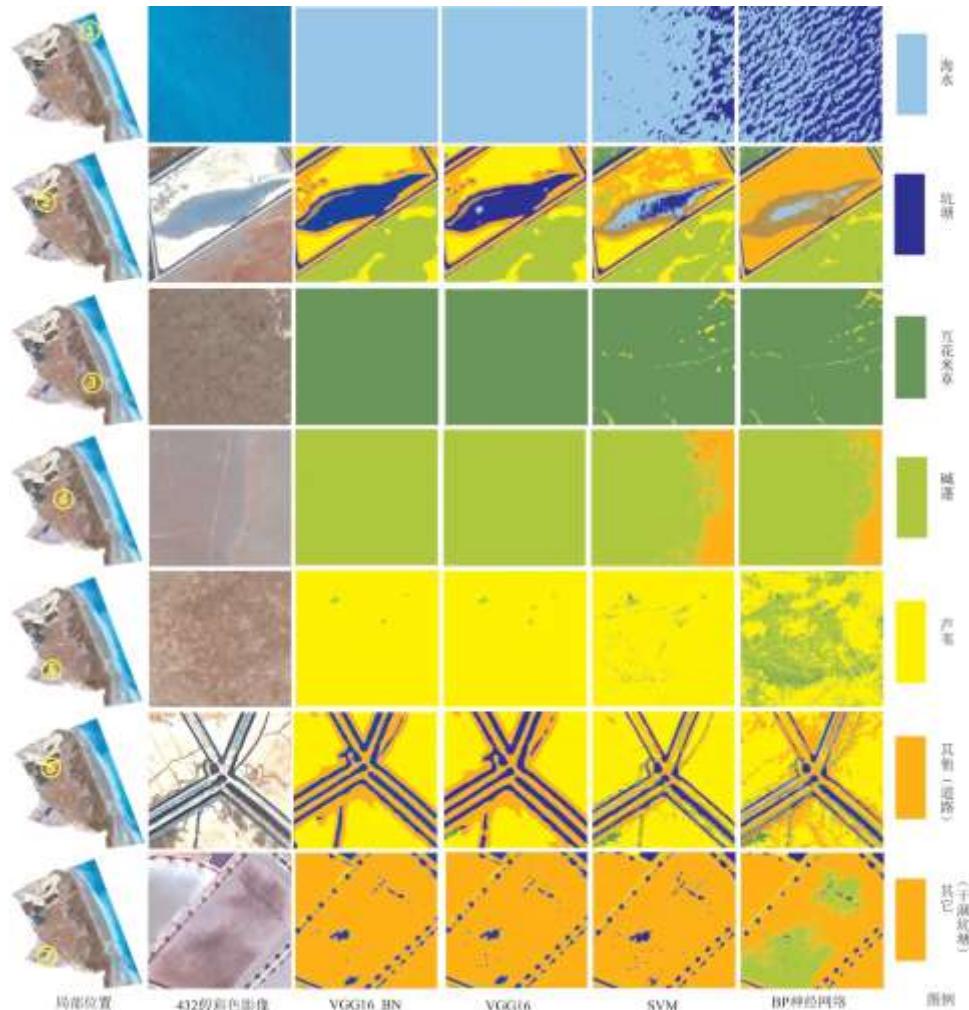


图 8 局部可视化分类图(2015 年)

4 结论

本研究以江苏省盐城滨海湿地珍禽国家级自然保护区核心区为研究区，基于不同时期 GF-2 高空间分辨率遥感影像，采用 VGG16_BN 网络模型对研究区进行信息分类提取，并对分类结果进行精度评价与分析。研究结果表明：(1)深度学习 VGG16_BN 算法对研究区影像分类精度理想，在不同算法分类结果对比中 VGG16_BN 的总体分类精度、Kappa 系数均为最高；(2)深度学习 VGG16_BN 与 VGG16 网络对于处理研究区道路、河流以及大面积同类地物具有较大优势，分类结果中道路与河流等线状特征和边缘信息较其他分类算法更为准确，对大块面状植被区域的分类结果类型均一，像元纯净；两种算法比较结果显示：VGG16_BN 较 VGG16 网络对地物纹理信息的提取能力更好，地物纹理特征表现更为连续，边界保持的更为完整；(3)VGG16_BN 网络能够应用于在小样本情况下快速精确提取高空间分辨率盐城滨海湿地覆被信息，拓展了该区域高分辨率遥感影像提取湿地信息的技术方法应用，可为研究区珍稀候鸟及原生湿地植被的保护提供科学数据支撑。

参考文献：

-
- [1] 李涛, 齐增湘, 王宽, 等. 1990~2013 年来洞庭湖区鸟类生物多样性热点区时空动态及变动机理[J]. 长江流域资源与环境, 2017, 26(11):1902-1911.
- [2] 布乃顺, 胡悦, 杨骁, 等. 互花米草入侵对长江河口湿地土壤理化性质的影响[J]. 长江流域资源与环境, 2017, 26(1):100-109.
- [3] 朱金峰, 周艺, 王世新, 等. 1975 年~2018 年白洋淀湿地变化分析[J]. 遥感学报, 2019, 23(5):971-986.
- [4] 薛星宇, 刘红玉. 基于 ALOS 影像的盐城海滨湿地遥感信息分类方法研究[J]. 遥感技术与应用, 2012, 27(2):248-255.
- [5] 王凯, 高媛赟, 温小荣, 等. 近 10 年盐城国家级珍禽自然保护区核心区湿地动态变化分析[J]. 森林工程, 2015, 31(1):17-21.
- [6] MAHDAVI S, SALEHI B, AMANI M, et al. A dynamic hierarchical feature selection method for object-based classification of wetlands[C]//2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). IEEE, 2017: 570-573.
- [7] 张磊, 宫兆宁, 王启为, 等. Sentinel-2 影像多特征优选的黄河三角洲湿地信息提取[J]. 遥感学报, 2019, 23(2):313-326.
- [8] LIN Y, SHEN M, LIU B, et al. Remote Sensing Classification Method of Wetland Based on AN Improved SVM[J]. ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2013, 1(1):179-83.
- [9] KE Z Y, AN R, LI X J. ANN Based High Spatial Resolution Remote Sensing Wetland Classification[C]//2015 14th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES). IEEE, 2015.
- [10] 张海涛, 刘景鑫, 赵晓晴, 等. 基于 VGG16 的急性淋巴细胞白血病血液细胞显微图像人工智能辅助诊断分类研究[J]. 中国医疗设备, 2019, 34(7):1-9.
- [11] 罗浩伦, 冯泽霖, 冉钟南, 等. 基于 VGG16 网络的茶叶嫩芽自动检测研究[J]. 农业与技术, 2020, 40(1):15-17.
- [12] 丁昱, 李灵巧, 杨辉华. 针对复杂背景的城管案件图像分类方法[J]. 计算机仿真, 2019, 36(5):381-385, 394.
- [13] 崔卫红, 熊宝玉, 张丽瑶. 多尺度全卷积神经网络建筑物提取[J]. 测绘学报, 2019, 48(5):597-608.
- [14] 李哲, 张沁雨, 彭道黎. 基于高分二号遥感影像的树种分类方法[J]. 遥感技术与应用, 2019, 34(5):970-982.
- [15] 刘博宇. 时序 NDVI 数据集螺线型构建及多形状参数变化检测[J]. 测绘学报, 2020, 49(2):268-268.
- [16] ROMINA M, TERESA P F, RODNEY B T, et al. Assessing performance of vegetation indices to estimate nitrogen nutrition index in pepper[J]. MDPI, 2020, 12(5):1-18.
- [17] 牟晓杰, 刘兴土, 阎百兴, 等. 中国滨海湿地分类系统[J]. 湿地科学, 2015, 13(1):19-26.

[18] TAN C, WANG D, ZHOU J, et al. Estimation of leaf nitrogen concentration in wheat by the combinations of two vegetation indexes using HJ-CCD images[J]. International Journal of Agriculture and Biology, 2018, 20(8) :1908–1914.

[19] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. ICLR, 2015:1–14.

[20] REZAEE M, MAHDIANPARI M, ZHANG Y, et al. Deep convolutional neural network for complex wetland classification using optical remote sensing imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(9) :3030–3039.

[21] CHENG G, LI Z, YAO X, et al. Remote sensing image scene classification using bag of convolutional features[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10) :1735–1739.

[22] LOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. ICML, 2015, 37:448–456.