

结合植被指数和卷积神经网络的遥感植被分类方法

许明珠¹, 徐浩², 孔鹏², 吴艳兰^{1,3,4*}¹安徽大学资源与环境工程学院, 安徽 合肥 230601;²北京空间飞行器总体设计部, 北京 100094;³信息材料与智能感知安徽省实验室, 安徽 合肥 230601;⁴安徽省地理信息智能技术工程研究中心, 安徽 合肥 230601

摘要 针对高分辨率遥感影像由于原始光谱信息较少而难以有效区分各类型植被, 而且城乡植被差异往往被忽视等问题, 并考虑到部分植被指数可以在一定程度上增大各植被类型间的差异, 提出一种结合植被指数的深度学习植被分类网络, 该网络在并联网结构的基础上, 引入密集连接模块与空洞空间金字塔池化模块, 增强各类型植被特征信息差异, 有效提高分类精度。除此之外, 本文充分考虑城乡植被差异, 分别对城市区域和农村区域进行验证分析, 城市区域植被分类提取中整体精度为 96.73%, F1 得分为 80.71%, 交并比为 69.91%, 农村区域植被分类提取中整体精度为 91.35%, F1 得分为 90.28%, 交并比为 82.41%, 各项精度指标均高于其他深度学习方法。结果表明提出方法能够较好地地区分各植被类型, 且适用于多源遥感影像的植被分类提取, 在城市绿地规划、农村基本农田监管等方面具有一定的应用价值。

关键词 遥感与传感器; 深度学习; 遥感; 国产高分二号; 植被指数; 植被分类

中图分类号 O436

文献标志码 A

DOI: 10.3788/LOP202259.2428005

Remote Sensing Vegetation Classification Method Based on Vegetation Index and Convolution Neural Network

Xu Mingzhu¹, Xu Hao², Kong Peng², Wu Yanlan^{1,3,4*}¹School of Resources and Environmental Engineering, Anhui University, Hefei 230601, Anhui, China;²Institute of Spacecraft System Engineering, Beijing 100094, China;³Information Materials and Intelligent Sensing Laboratory of Anhui Province, Hefei 230601, Anhui, China;⁴Anhui Engineering Research Center for Geographical Information Intelligent Technology, Hefei 230601, Anhui, China

Abstract Due to the lack of original spectral information, high-resolution remote sensing images are difficult to effectively distinguish various types of vegetation, and the differences between urban and rural vegetation are often ignored and considering that certain vegetation indices somewhat increase the differences among different vegetation types, this paper proposes a deep learning vegetation classification network based on a vegetation index that combines artificial features and spectral information. Based on a parallel network structure, a dense connection module and atrous spatial pyramid pooling module are introduced to enhance the differences in vegetation feature information and effectively improve classification accuracy. Besides, taking full account of the differences between urban and rural vegetation, this paper verifies and analyzes urban and rural areas, respectively. The overall accuracy of urban vegetation classification and extraction is 96.73%, the F1 score is 80.71%, and the intersection-merge ratio is 69.91%. The overall accuracy in classifying and extracting vegetation in rural areas is 91.35%, the F1 score is 90.28%, and the intersection-merge ratio is 82.41%. Each accuracy index exceeds that of other depth learning methods. The results confirm that this method better distinguishes different vegetation types, is suitable for classifying and extracting vegetation from multi-source remote sensing images, and has a definite value for urban green space planning, rural basic farmland supervision, etc.

Key words remote sensing and sensors; deep learning; remote sensing; GF-2; vegetation index; vegetation classification

收稿日期: 2021-09-14; 修回日期: 2021-10-18; 录用日期: 2021-11-03

基金项目: 国家自然科学基金(41971311)、安徽省科技重大专项(201903a07020014)

通信作者: *wuyanlan@ahu.edu.cn

1 引言

植被的生长状态与其所在地的气候、土壤、水文条件等密切相关^[1]。光谱信息是遥感影像用于地物提取^[2]、分类^[3]以及目标识别^[4]的最主要信息,利用高分辨率遥感影像是研究植被覆盖、结构组成以及动态变化^[5]的重要手段。

遥感植被提取方法主要包括传统的机器学习方法和深度学习方法,传统的机器学习方法包括随机森林算法、支持向量机算法、最大似然法等。例如,韩林果等^[6]在土地利用类型图的基础上利用最大似然法提取冬小麦,提取结果与官方统计数据基本一致,但是最大似然法应用于多分类很难得到较高的分类精度^[7]。史飞飞等^[8]基于高分辨率遥感影像,应用支持向量机算法对典型农作物进行分类识别,各类型作物误分较少,但是该方法很难找到合适的核函数^[9],并且在应用于多分类时会出现计算量大、训练时间长等问题。随机森林方法学习速率快,也不需要特征选择^[10],更适用于多分类问题,谷晓天等^[11]基于支持向量机与随机森林等算法分别对高海拔复杂地形区域进行土地分类,结果表明随机森林算法的分类精度明显高于支持向量机算法,尤其是对复杂地形区域的土地利用信息提取,但随机森林算法也存在易产生过拟合的问题^[12]。同时以上方法普遍存在特征或尺度的选择问题,自动化程度也较低。

深度学习方法因其学习能力强、自动化程度高,成为当前大数据时代植被分类更有效的方法^[13-14]。其本质是构建含有多个隐含层的深度神经网络模型,从而得到大量具有代表性的深度特征^[15-16],目前已被广泛应用于植被研究^[17-18]。马海艺等^[19]利用全卷积神经网络对植被信息进行提取,结果表明该网络可以有效减少植被的误分与漏分,并对小面积植被的整体提取有良好的提取效果。但该方法在大面积植被以及多分类上提取结果不够精细,图像过于模糊^[20]。针对以上问题,林锦涵等^[21]基于 SegNet 网络实现了对植被的快速精细化分类,却无法避免细小植被的漏提情况。为了解决

这个问题,Gui等^[22]基于 UNet 网络对林地进行分类,使细小植被也得到了较为完整的提取结果。Morales等^[23]采用 Deeplab-V3+ 模型提取棕榈树,由于 Deeplab-V3+ 使用带有空洞卷积的空间金字塔池化^[24]做语义分割,引入更多尺度的特征信息,因此能识别出独立生长以及植被部分覆盖的棕榈树,从而得到比 UNet 更加完整的提取结果。Yao等^[25]借鉴 Rosanne等^[26]的经验,在 FC-DenseNet 网络中加入坐标信息,有效利用多层特征减少边界信息的丢失。虽然深度学习方法在土地利用分类上已经取得良好的应用效果,但是对于植被多分类,高分辨率遥感影像的光谱信息较少,各植被类型光谱差异较小,仅高分辨率遥感影像原始光谱信息很难得到较高的分类精度,而部分植被指数可以一定程度上增大各植被类型间的差异,结合植被指数的深度学习方法可以得到更高的植被分类精度。

针对高分辨率遥感影像虽然空间分辨率高,但由于光谱信息较少而难以有效区分各类型植被,而且城乡植被差异往往被忽视等问题,本文提出一种结合植被指数的深度学习植被分类网络,该网络融合人工特征和光谱信息,在并联网结构的基础上,引入密集连接模块与空洞空间金字塔池化模块,增强各类型植被特征信息差异,有效提高分类精度,并在不同城乡环境下进行了验证分析。

2 研究方法

本文结合遥感影像原始波段信息及其植被指数,借鉴 Sun等^[27]提出的高分辨率网络,提出采用并联网结构的深度学习(HRDN)方法,该方法在并联网结构的基础上采用重复的多尺度融合方法在保留不同分辨率信息的同时实现了对空间信息的有效利用。此外,每支网络都引入了 DenseNet 网络中的密集连接模块,用以提高特征信息的利用能力,并且在分辨率最低的第 4 层子网中加入了空洞空间金字塔池化(ASPP)模块,将所给定的输入以不同采样率的空洞卷积并行采样,增加不同尺度信息感受野,网络结构图 1 所示。遥感影像与植被指数先经过步长为 2 的

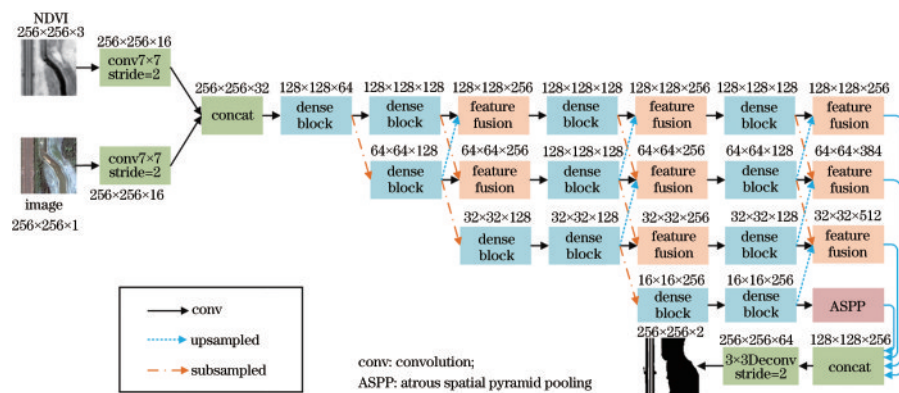


图 1 网络结构流程

Fig. 1 Flow chart of network structure

7×7 卷积降低特征图大小,将两幅特征图连接后进入密集连接块,每进入一个密集连接块后都要进行一次下采样,每一次下采样后在相应的子网保持特征图大小,共生成了 4 条子网,从上往下分辨率依次减小。在特征恢复中,将第二、第三和第四条子网的特征图分别通过连续上采样得到与第 1 条子网相同分辨率的特征图,最后将 4 幅特征图合并后利用上采样恢复原始影像大小,实现植被类型的精确分割。

2.1 密集连接块

传统的卷积神经网络在 L 层卷积网络中有 L 个连接,而在本文使用的密集连接块中,每一层的输入的特征是前面所有层输出特征的并集,这就使得在一个 L 层卷积网络中有 $L(L+1)/2$ 个连接,但是这种连接方

式会产生大量特征图,因此设置增值率(k)来控制这一过程,密集连接块中以转换层(translation layer)连接各中间特征图,每个转换层包括 1 个批量归一化层(GN)、1 个非线性性激活层(RuLu)、1 个 3×3 卷积层和 1 个用于防止过拟合的 dropout 层,如图 2 所示。由于本文方法使用的 Batch 较小,所以将原先的批量标准化(BN)层改为了 GN 层^[28],这种密集连接的结构使得各植被类型的特征得到了有效的利用,加强了整个网络对特征信息的传播,缓解了梯度消失的问题,其计算可表示为

$$X_l = H_l[(x_0, x_1, \dots, x_{l-1})], \quad (1)$$

式中: x_l 表示第 l 层的输出; $H_l(\cdot)$ 表示非线性操作组合,包括 GN 层、ReLU、3×3 卷积层以及 dropout 层。

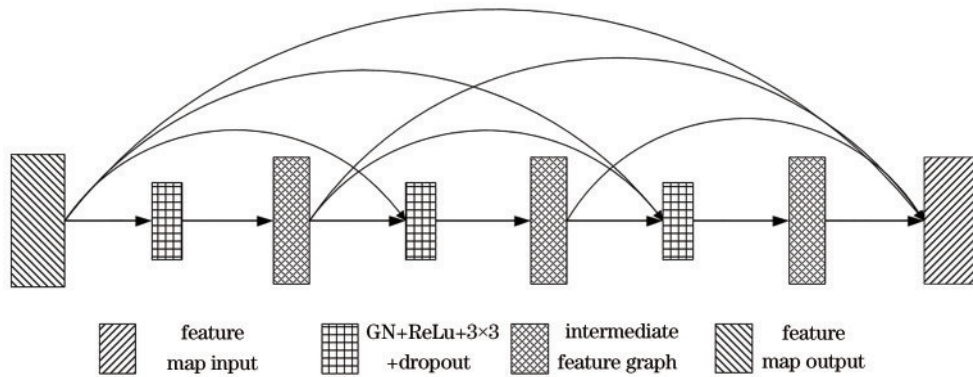


图 2 密集连接块
Fig. 2 Dense blocks

2.2 空洞空间金字塔池化

传统的网络为了提高感受野往往采用池化和下采样来降低影像分辨率,再通过线性插值或反卷积等上采样操作恢复分辨率,在这个过程中会造成特征信息的丢失,为了解决这个问题,ASPP^[29]模块被提出,使网络在提高感受野的同时实现全局平均池化得到图像

及全局特征,并采用上采样恢复原有分辨率。ASPP 由多条平行的不同空洞率的卷积支路组成类似于金字塔方式对传入的卷积特征层进行卷积,可以在不降低分辨率的情况下增大感受野,同时得到多尺度的特征信息,如图 3 所示。在网络分辨率最低层加入了 ASPP 模块,该模块包括两部分:第一部分包括一个 1×1 卷

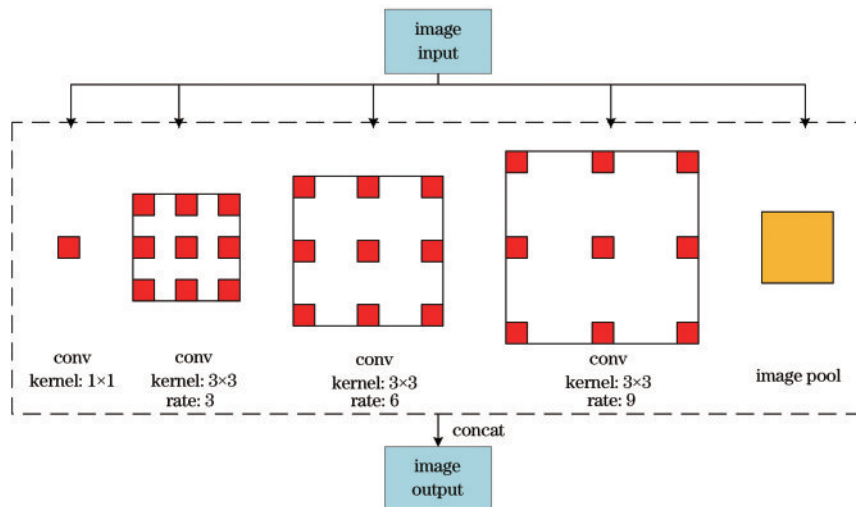


图 3 ASPP 模块
Fig. 3 Atrous spatial pyramid pooling (ASPP) block

积和 3 个空洞率分别为 3、6、9 的 3×3 卷积;第二部分是一个全局平均池化层,获得图像级特征,最后将两部分结果进行拼接卷积融合。

2.3 多分辨率特征融合

将多分辨率特征图进行融合可以更大程度地保留各分辨率特征,本文高分辨率与低分辨率特征图融合有 3 种方式,如图 4 所示:1) 高分辨率特征图不变,将低分辨率特征图进行上采样插值至与高分辨率特征图

大小相同,再将两幅特征图叠加通道使用 ReLU 激活函数输出;2) 低分辨率特征图不变,将高分辨率特征图采用 3×3 卷积降低到与低分辨率特征图相同大小,再将两幅特征图叠加通道使用 ReLU 激活函数输出;3) 高、中、低 3 种分辨率特征图融合时保持中分辨率的特征图不变,将高分辨率特征图进行卷积、低分辨率特征图进行上采样,分别得到两幅中分辨率特征图,最后将 3 幅特征图通道叠加,最后使用 ReLU 激活函数输出。

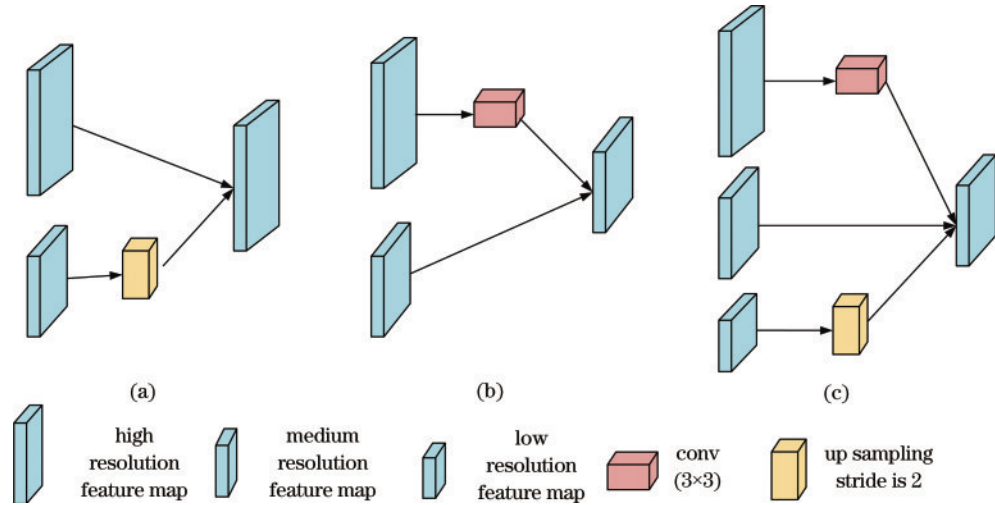


图 4 多分辨率特征融合方式。(a)方式 1);(b)方式 2);(c)方式 3)
Fig. 4 Multiresolution feature fusion modes. (a) Mode 1); (b) mode 2); (c) mode 3)

3 数据与实验

3.1 数据介绍

3.1.1 遥感影像数据

本文使用的国产高分二号 (GF-2) 遥感影像包含空间分辨率为 4 m 的多光谱影像和分辨率为 1 m 的全色影像,其中多光谱影像包括 4 个波段信息,蓝色 (B1): $0.45 \sim 0.52 \mu\text{m}$,绿色 (B2): $0.52 \sim 0.59 \mu\text{m}$,红色 (B3): $0.63 \sim 0.69 \mu\text{m}$ 和近红外 (B4): $0.77 \sim 0.89 \mu\text{m}$,全色影像包括 1 个波段信息,谱段: $0.45 \sim$

$0.90 \mu\text{m}$,成像宽幅为 45 km,空间分辨率优于 1 m。本研究将影像经辐射定标和大气校正处理以消除大气散射与地形、邻近地物等因素的影响,再经过 NNDiffuse Pan Sharping 数据融合算法,将多光谱影像和全色影像进行融合,最终得到分辨率为 1 m 的多光谱影像。

模型训练所用影像包括城区与农村区域,其中,训练区影像面积约为 366.88 km^2 ,测试区影像有 8 幅,面积均约为 4.19 km^2 ,并且使用不同传感器和不同地区的遥感数据对本文提出方法的适用性进行验证。具体影像信息如表 1 所示。

表 1 影像参数
Table 1 Image parameters

Use	Sample	Model testing	Universal validation 1	Universal validation 2
Sensor	GF2-PMS2	GF2-PMS2	GF6-PMS	GF2-PMS2
Region	Hefei	Hefei	Hefei	Beijing
Spatial resolution /m	1	1	2	1
Image acquisition date	2015-08-03	2016-08-27 2015-08-03	2018-10-04	2016-08-27
Midline coordinates	E117.3, N31.7	E116.8, N40.4 E117.3, N31.7	E117.4, N32.1	E116.8, N40.4

3.1.2 植被指数数据

本文在对比归一化植被指数 (NDVI)、差值植被指数 (DVI)、比值植被指数 (RVI) 等植被指数的实验结果后,最终确定使用植被指数 NDVI。NDVI 是最常

用的植被指数之一,能够消除部分与大气条件有关的辐射变化影响,被广泛应用于干旱监测以及农业生产等领域。

3.2 分类系统

本文根据国家标准《土地利用现状分类》，结合实际情况确定本文的分类系统分别为耕地、草地、林地、水生植被以及非植被 5 种类型。其中耕地包括旱地作物和水田作物；草地包括人工草地和荒草地；林地包括乔木林地和灌木林地；水生植被包括水体内的藻类或浮水植物、挺水植物等；非植被类包括建筑、道路等非植被要素。

3.3 样本库构建

样本库为合肥地区 2015 年 8 月的遥感影像，样本

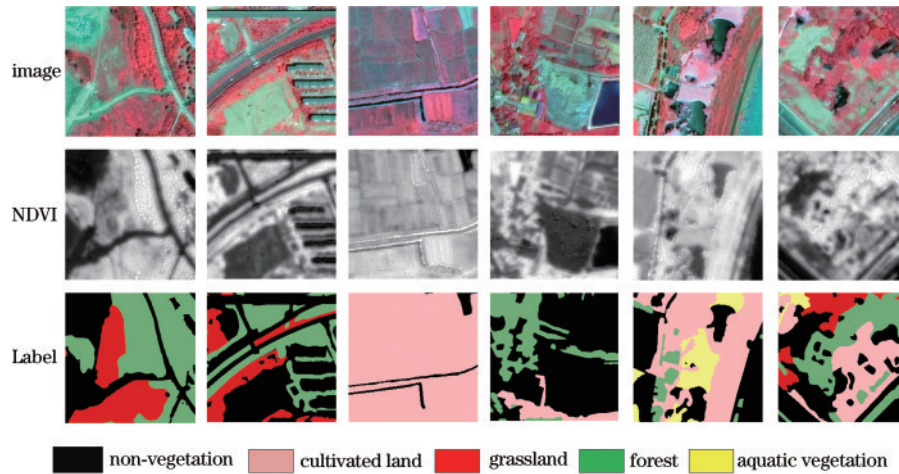


图 5 遥感影像植被样本示例

Fig. 5 Example of vegetation samples from remote sensing images

3.4 精度评价指标

本文植被分类提取结果采用总体准确度(OA)、F1分数和交并比(IOU)进行精度评价。OA(R_{OA})指识别的所有类别中,正确识别出来的类别的像元个数之和与测试影像总像元数的比值。F1分数(F_1)可以通过正确率(P)和召回率(R)来计算,是 P 和 R 的调和平均值的有效的评价指标。 P 是正确像素在预测结果中的比例, R 表示地面真实值中正确像素的比例。IOU (I_{IOU})是指一个特定类的预测区域和地面真实区域在其交集上的并集,用来评价形状和面积。 P 、 R 、OA、F1和IOU公式分别如下:

$$R = \frac{S_{TP}}{S_{TP} + S_{FN}}, \quad (2)$$

$$F_1 = 2 * \frac{P * R}{P + R}, \quad (3)$$

$$R_{OA} = \frac{S_{TP} + S_{TN}}{S_{TP} + S_{TN} + S_{FP} + S_{FN}}, \quad (4)$$

$$I_{IOU} = \frac{S_{TP}}{S_{TP} + S_{FN} + S_{FP}}, \quad (5)$$

式中: S_{TP} 表示正确分类的正样本个数; S_{FP} 表示错误分类的正样本个数; S_{TN} 表示正确分类的负样本个数; S_{FN} 表示错误分类的负样本个数。

3.5 软硬件环境配置

网络是在 Tensorflow1.13.1 框架下基于 python3.6 进行编译的,所有模型均运行在 Windows10 的 64 位操

作系统上,硬件配置为 Inter Xeon Gold 6148CPU 和 Nvidia Tesla V100-PCIE(16 GB)显卡以及 256 GB 内存。本文实验采用了语义分割领域常用的交叉熵损失函数并选择 Adam 作为网络优化算法。模型的初始化学率设定为 10^{-3} ,同时平行网络设置一个自动调整学习率的方法即根据训练轮数设定不同的等级,当训练次数达到不同等级时学习率自动降低为 1/10。每一轮迭代次数为 2200,批次大小设置为 6,正则化系数为 10^{-3} ,轮数为 80 轮。

库包括多光谱遥感影像、NDVI 和目视解译结果 3 部分。Label 是根据不同植被类型的遥感影像特征在 Arcgis 中人工目视解译得到,耕地形状规则、纹理细腻,草地颜色较浅、纹理细腻均匀,林地主要呈斑块状或线状,纹理为颗粒状,水生植被呈粉红色。本文林地样本库共 15860 幅遥感影像子图及其对应的 NDVI 和 Label,其中 12660 幅用于模型训练,3200 幅用于模型精度验证。样本示例如图 5 所示。

作系统上,硬件配置为 Inter Xeon Gold 6148CPU 和 Nvidia Tesla V100-PCIE(16 GB)显卡以及 256 GB 内存。本文实验采用了语义分割领域常用的交叉熵损失函数并选择 Adam 作为网络优化算法。模型的初始化学率设定为 10^{-3} ,同时平行网络设置一个自动调整学习率的方法即根据训练轮数设定不同的等级,当训练次数达到不同等级时学习率自动降低为 1/10。每一轮迭代次数为 2200,批次大小设置为 6,正则化系数为 10^{-3} ,轮数为 80 轮。

4 结果与讨论

4.1 实验结果

利用本文方法对合肥地区 GF-2 遥感影像进行测试,将测试样本分为城市区域和农村区域,影像 1、2、3、4 为城市区域,主要包括大面积的林地与部分草地,其中影像 3 的目视解译结果中没有耕地类型,影像 4 的目视解译结果中没有耕地与水生植被,影像 5、6、7、8 为农村区域,主要包括大面积的耕地与部分林地、草地和水生植被。为了体现出 NDVI 对于本文方法应用于植被分类的有效性,在保证训练数据完全相同的情况下,将本文方法与不加 NDVI 的 HRDN 模型植被分类提取结果进行对比,如表 2 所示。

4.1.1 城市区域

图 6 为城市区域分类结果的对比图,结合图 6 与

表 2 HRDN加入 NDVI前后分类精度对比。(a)、(b)分别为未融合 NDVI 和融合 NDVI 模型的分类精度

Table 2 Comparison of classification accuracy of HRDN before and after adding NDVI. (a), (b) are classification accuracies of fused NDVI model and unfused NDVI model, respectively unit: %

Region	Image	Cultivated land		Grassland		Forest		Aquatic vegetation		Mean F1 score	Mean IOU	OA
		F1	IOU	F1	IOU	F1	IOU	F1	IOU			
City	Image 1	14.53	9.01	18.22	10.02	63.33	46.33	/	/	32.03	21.79	87.02
	Image 2	15.67	8.50	13.59	7.29	67.49	50.93	67.28	50.70	41.01	29.36	89.79
	Image 3	/	/	12.44	6.63	90.27	82.27	/	/	51.36	44.45	94.88
	Image 4	/	/	14.94	8.07	83.56	71.77	/	/	49.25	39.92	93.90
	All images	15.10	8.76	14.80	8.00	76.16	62.83	67.28	50.70	43.41	33.88	91.40
Rural	Image 5	89.05	80.26	87.80	78.26	79.20	65.56	78.07	64.02	83.53	72.03	78.49
	Image 6	86.19	75.74	81.89	69.33	77.21	62.87	77.32	63.03	80.65	67.74	77.90
	Image 7	86.71	76.54	84.44	73.07	80.99	68.05	80.68	67.61	83.21	71.32	82.60
	Image 8	72.08	56.35	70.97	55.00	61.11	44.00	60.68	43.11	66.21	49.62	61.16
	All images	83.51	72.22	81.28	68.92	74.63	60.12	74.19	59.44	78.40	65.18	75.04

(a)

Region	Image	Cultivated land		Grassland		Forest		Aquatic vegetation		Mean F1 score	Mean IOU	OA
		F1	IOU	F1	IOU	F1	IOU	F1	IOU			
City	Image 1	53.23	36.27	57.49	40.34	82.45	70.14	/	/	64.39	48.92	93.48
	Image 2	56.02	38.91	62.31	45.25	84.5	96.56	84.48	73.12	71.83	63.46	94.79
	Image 3	/	/	77.61	63.42	98.34	96.73	/	/	87.98	80.08	99.25
	Image 4	/	/	75.32	60.41	97.87	95.83	/	/	86.60	78.12	99.38
	All images	54.63	37.59	68.18	52.36	90.79	89.82	84.48	73.12	82.14	67.65	96.73
Rural	Image 5	90.60	82.82	88.58	79.50	85.49	74.66	84.82	73.64	87.37	77.66	87.20
	Image 6	94.33	89.27	92.50	86.05	91.71	84.69	91.67	84.62	92.55	86.16	93.08
	Image 7	94.34	89.29	93.14	87.16	92.52	86.08	92.43	85.93	93.11	87.11	94.41
	Image 8	88.29	79.04	86.44	76.12	89.03	80.23	88.59	79.52	88.09	78.73	90.70
	All images	91.89	85.11	90.17	82.21	89.69	81.42	89.38	80.93	90.28	82.41	91.35

(b)

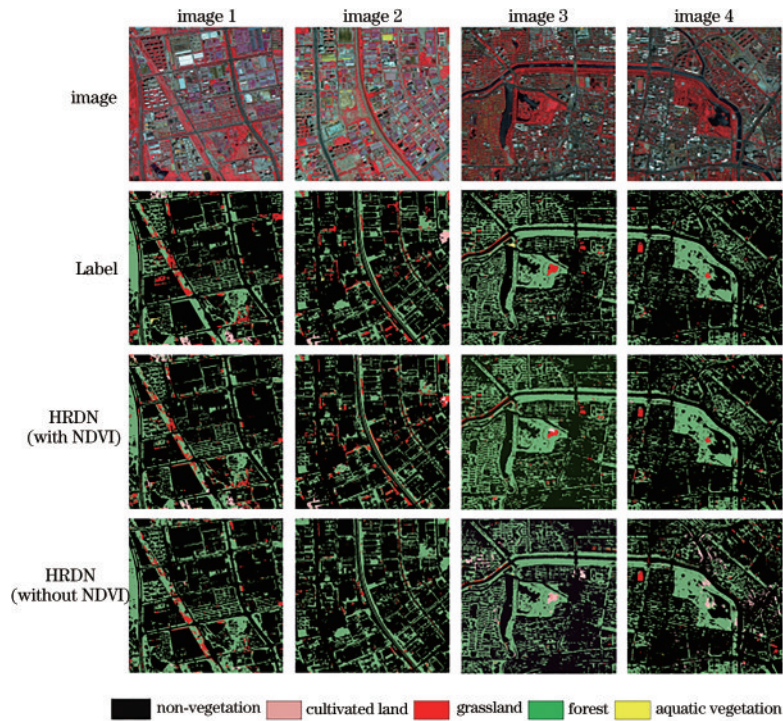


图 6 HRDN加入 NDVI前后城市分类结果图

Fig. 6 City classification results before and after HRDN joined NDVI

表 2 可以看出,加入 NDVI 后模型对城市草地的提取能力有明显提升,对耕地的误分也有所减少,加入 NDVI 后城市区域的耕地、草地、林地、水生植被 4 种植被类型的 F1 得分分别为 54.63%、68.18%、90.79%、

84.48%，交并比分别为 37.59%、52.36%、89.82%、73.12%，整体精度为 96.73%。而不加 NDVI 的模型对 4 种植被类型分类精度，F1 得分分别为 15.10%、14.80%、76.16%、67.28%，交并比分别为 8.76%、8.00%、62.83%、50.70%，整体精度为 91.40%，远低于加入 NDVI 后的分类精度，证明了 NDVI 对于本文方法应用于城市植被分类的有效性。

除此之外，混淆矩阵通过计算统计每个像元的分类情况，可以更直观地评估本文方法对各植被类型的分类准确率，包括生产者精度(PA)、用户精度(UA)、Kappa 系数。表 3 为本文方法在城市区域对 4 幅影像的混淆矩阵，4 幅影像的 Kappa 系数最低为 84.50%，最高达到 98.37%，从 4 幅影像的混淆矩阵来看林地的精度最高，耕地和草地多误分为林地。

表 3 城市区域影像的混淆矩阵。(a)~(d)分别为城市区域 4 幅影像的混淆矩阵

Table 3 Confusion matrices of images in urban areas. (a)~(d) are confusion matrices of four images in urban area respectively

Image 1	Cultivated land	Grassland	Forest	Aquatic vegetation	UA / %
Cultivated land	47.35	2.22	1.21	/	60.95
Grassland	8.52	56.64	4.45	/	60.33
Forest	33.24	31.31	85.02	/	90.84
Aquatic vegetation	0	0	0.01	/	0
PA / %	47.35	56.64	85.02	/	
Kappa:84.50%					
(a)					
Image 2	Cultivated land	Grassland	Forest	Aquatic vegetation	UA / %
Cultivated land	58.62	6.73	0.14	0	53.63
Grassland	6.47	60.63	2.87	27.66	66.91
Forest	31.86	28.72	93.15	1.1	84.63
Aquatic vegetation	0	0.02	0.02	67.26	58.37
PA / %	58.62	60.63	93.15	67.26	
Kappa:85.85%					
(b)					
Image 3	Cultivated land	Grassland	Forest	Aquatic vegetation	UA / %
Cultivated land	/	0	0	/	0
Grassland	/	81.38	0.42	/	79.97
Forest	/	18.43	99.56	/	98.68
Aquatic vegetation	/	0.12	0.20	/	0
PA / %	/	81.38	99.35	/	
Kappa:98.37%					
(c)					
Image 4	Cultivated land	Grassland	Forest	Aquatic vegetation	UA / %
Cultivated land	/	0.37	0.14	/	0
Grassland	/	85.08	1.09	/	70.40
Forest	/	14.16	97.89	/	99.47
Aquatic vegetation	/	0.05	0.01	/	0
PA / %	/	85.08	97.89	/	
Kappa:98.29%					
(d)					

4.1.2 农村区域

图 7 为农村区域的对比图，从分类结果可以看出，加入 NDVI 后对耕地的漏提明显减少，同时对植被整体提取更加完整，从表 2 可以看出，对农村区域的耕地、草地、林地、水生植被 4 种植被类型分类结果的 F1 得分分别为 91.89%、90.17%、89.69%、89.38%，交并比分别为 85.11%、82.21%、81.42%、80.93%，整体精度为 91.35%，而不加 NDVI 的模型对 4 种植被类型分类精度，F1 得分分别为 83.51%、81.28%、74.63%、74.19%，交并比分别为 72.22%、68.92%、60.12%、59.44%，整体精度为 75.04%，同样远低于加入 NDVI 后的分类精度，证明了 NDVI 对于本文方法应用于农村植被分类的有效性。

表 4 为本文方法在农村区域对 4 幅影像的混淆矩

阵，4 幅影像的 Kappa 系数均超过 80%，最高达到 91.78%，从 4 幅影像的混淆矩阵来看，耕地、林地、水生植被的 UA 和 PA 精度较高，各植被类型之间误分较少，草地的 UA 和 PA 精度较低，与林地和耕地有部分误分。

4.1.3 城市区域与农村区域分类精度对比

对比城市区域与农村区域各植被类型的分类精度可以发现，城乡植被分类精度差距较大，城市区域耕地与草地的各项精度远低于农村区域，林地与水生植被的提取精度相近，分析原因是城市区域内耕地稀少，草地多为人工草地，斑块面积小且破碎，而农村区域的耕地面积较大，且较为完整，草地多为荒草地，且面积较大，因此存在较大的城乡差异。

4.2 不同深度学习方法分类结果对比

为了证明本文提出的模型应用于植被分类的优越

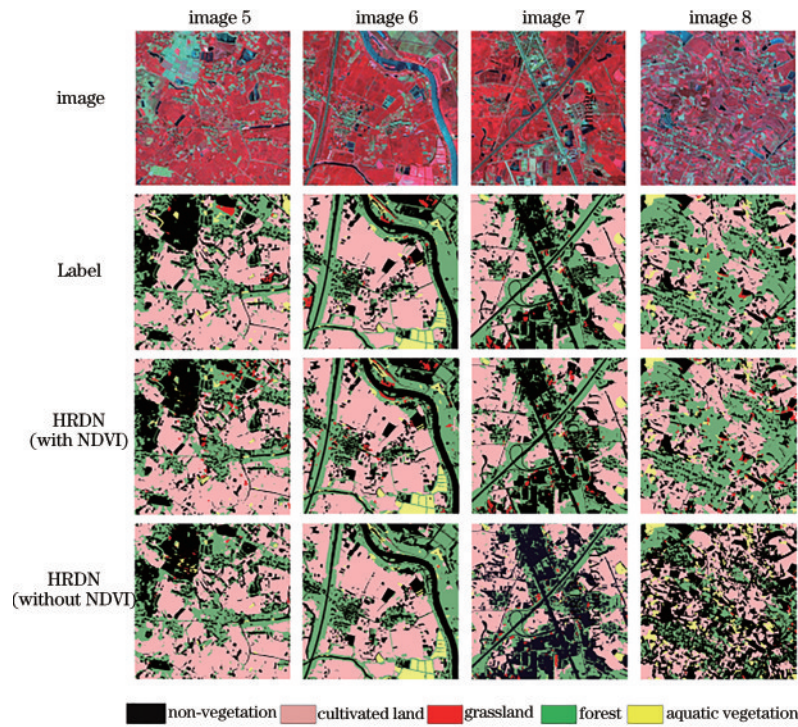


图 7 HRDN加入NDVI前后农村分类结果图

Fig. 7 Rural classification results before and after HRDN joined NDVI

表 4 农村区域影像的混淆矩阵。(a)~(d)分别为农村区域4幅影像的混淆矩阵

Table 4 Confusion matrices of images in rural areas. (a)~(d) are confusion matrices of four images in rural areas respectively

Image 5	Cultivated land	Grassland	Forest	Aquatic vegetation	UA / %
Cultivated land	87.51	2.00	8.14	27.34	93.92
Grassland	2.03	25.05	2.18	0.71	11.80
Forest	7.85	60.66	80.87	22.70	77.96
Aquatic vegetation	0.27	4.65	0.54	42.39	66.73
PA / %	87.51	25.05	80.87	42.39	
Kappa: 80.61%					
(a)					
Image 6	Cultivated land	Grassland	Forest	Aquatic vegetation	UA / %
Cultivated land	94.71	16.74	5.90	1.09	93.96
Grassland	0.67	37.79	0.53	0.23	53.04
Forest	4.47	36.79	92.50	7.27	88.87
Aquatic vegetation	0.06	0.24	0.42	89.87	92.32
PA / %	94.71	37.79	92.5	89.87	
Kappa: 90.05%					
(b)					
Image 7	Cultivated land	Grassland	Forest	Aquatic vegetation	UA / %
Cultivated land	93.51	7.65	5.32	0.96	95.19
Grassland	0.20	70.67	1.55	0.08	52.67
Forest	5.41	18.45	91.74	9.61	91.76
Aquatic vegetation	0.24	0.09	0.16	86.54	85.99
PA / %	93.51	70.67	91.74	86.54	
Kappa: 91.78%					
(c)					
Image 8	Cultivated land	Grassland	Forest	Aquatic vegetation	UA / %
Cultivated land	88.8	40.70	6.01	13.83	87.79
Grassland	0.14	26.37	0.24	0.26	70.91
Forest	10.19	29.37	93.22	15.85	89.07
Aquatic vegetation	0.68	0.71	0.26	69.53	83.87
PA / %	88.8	26.37	93.22	69.53	
Kappa: 86.23%					
(d)					

性,在保证训练数据完全相同的情况下,将相同的训练数据应用于 Deeplab-V3+、BiseNet、DCCN 3 种深度学习模型,从而对城市以及农村的遥感影像进行植被分类。

4.2.1 城市区域

图 8 为 3 种模型对城市区域影像的分类结果与目

视解译结果对比图,从图中可以看出,3 种网络中 Deeplab-V3+ 的分类结果最接近目视解译结果,有部分草地被误分为林地, BiseNet 明显将部分耕地和林地误分为草地, DCCN 将多数林地误分为耕地。

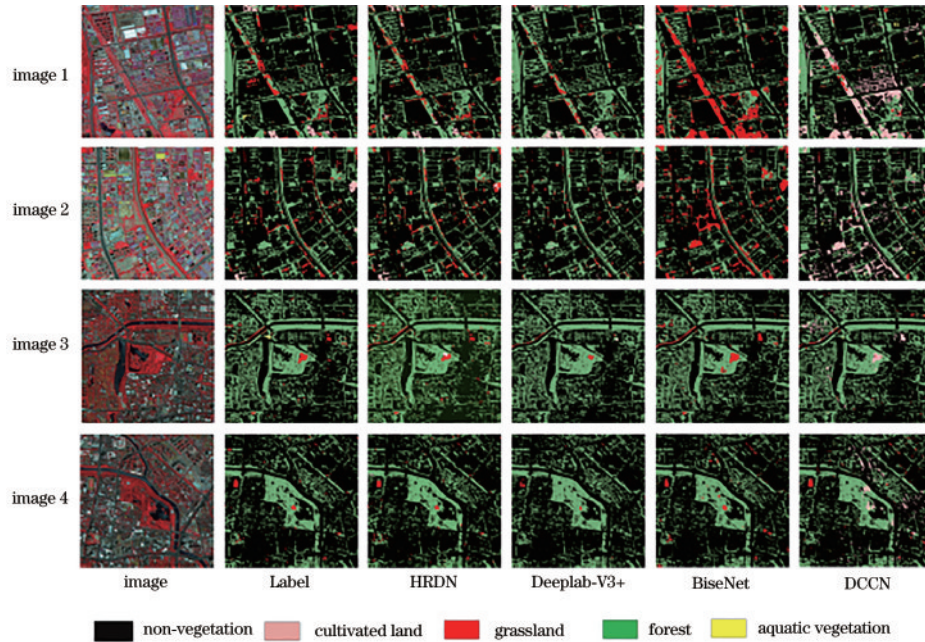


图 8 HRDN、Deeplab-V3+、BiseNet、DCCN 对城市区域植被分类结果图

Fig. 8 Result map of vegetation classification in urban areas by HRDN, Deeplab-V3+, BiseNet, and DCCN

4.2.2 农村区域

图 9 为 3 种模型对农村区域影像的分类结果与目视解译结果对比图,从图中可以看出,与城市区域相似,3 种网络中 Deeplab-V3+ 的分类结果更接近目视

解译结果,但是对草地的误分较多。 BiseNet 将部分草地误分为林地,部分水生植被被误分为草地。 DCCN 对农村区域植被存在大量漏分,分类结果较为破碎。

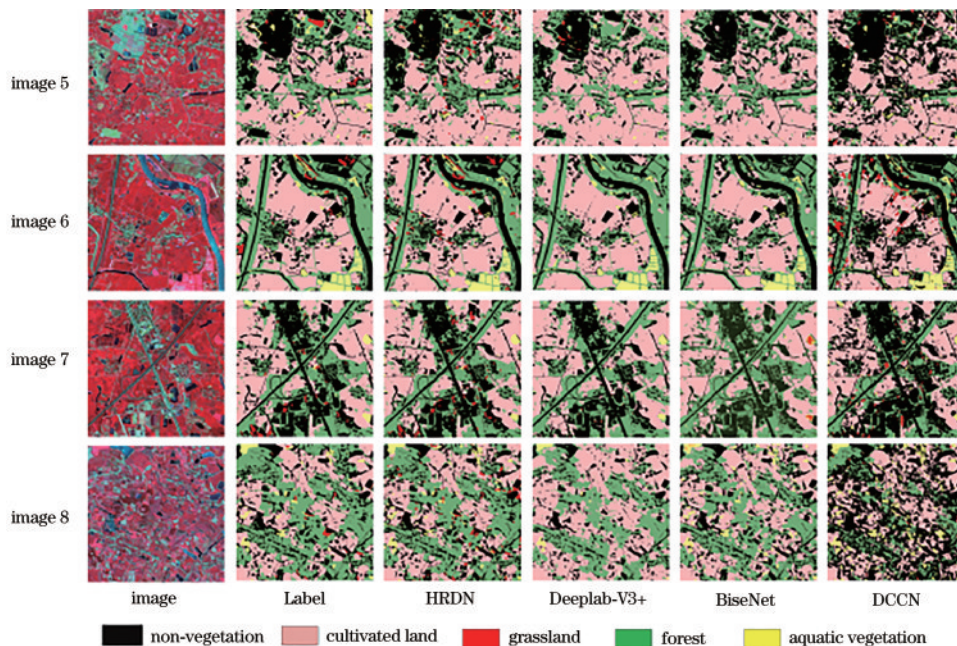


图 9 HRDN、Deeplab-V3+、BiseNet、DCCN 对农村区域植被分类结果图

Fig. 9 Result map of vegetation classification in rural areas by HRDN, Deeplab-V3+, BiseNet, and DCCN

4.2.3 城市区域与农村区域分类精度对比

表 5 列出了 3 种深度学习方法的分类精度,从精度上看, Deeplab-V3+ 各项分类精度比 BiseNet 和 DCCN 高,与本文方法相比, Deeplab-V3+ 对城市区域植被分类中,耕地、草地、林地、水生植被 4 种植被类型 F1 得分分别为 47.40%、35.29%、85.99%、80.06%,

IOU 分别为 31.40%、21.46%、75.80%、66.74%,整体精度为 94.45%,3 种指标精度均低于本文方法。对农村区域植被分类中,耕地、草地、林地、水生植被上 F1 得分分别为 86.76%、85.71%、84.52%、84.17%, IOU 分别为 77.01%、75.34%、73.33%、72.83%,整体精度为 85.25%,3 种指标精度同样低于本文方法,

表 5 3 种方法分类结果。(a)、(b)、(c)分别为 Deeplab-V3+、BiseNet、DCCN 模型分类提取结果

Table 5 Classification results of three methods. (a), (b), (c) are classification and extraction results of Deeplab-V3+, BiseNet, and DCCN models, respectively unit: %

Region	Image	Cultivated land		Grassland		Forest		Aquatic vegetation		Mean F1 score	Mean IOU	OA
		F1	IOU	F1	IOU	F1	IOU	F1	IOU			
City	Image 1	39.60	24.69	36.60	22.40	79.31	65.72	/	/	51.84	37.60	92.48
	Image 2	55.19	38.11	38.50	23.84	80.10	66.80	80.06	66.74	63.46	48.87	93.32
	Image 3	/	/	30.68	18.12	92.60	86.21	/	/	61.64	52.17	95.77
	Image 4	/	/	35.37	21.48	91.17	83.77	/	/	63.27	52.63	96.23
	All images	47.40	31.40	35.29	21.46	85.99	75.80	80.06	66.74	60.05	46.21	94.45
Rural	Image 5	90.00	81.81	89.19	80.49	85.50	74.67	84.72	73.49	87.35	78.99	85.96
	Image 6	91.47	84.29	90.07	81.93	88.35	79.13	88.40	79.21	89.57	81.14	88.57
	Image 7	87.98	78.54	86.66	76.46	85.10	74.07	85.00	73.92	86.19	75.75	87.53
	Image 8	77.59	63.39	76.95	62.46	79.12	65.46	78.57	64.70	70.06	64.00	78.92
	All images	86.76	77.01	85.71	75.34	84.52	73.33	84.17	72.83	83.29	74.97	85.25

(a)

Region	Image	Cultivated land		Grassland		Forest		Aquatic vegetation		Mean F1 score	Mean IOU	OA
		F1	IOU	F1	IOU	F1	IOU	F1	IOU			
City	Image 1	0	0	35.99	21.94	67.16	50.56	/	/	51.57	36.25	88.42
	Image 2	0	0	35.52	21.59	68.77	52.41	68.72	52.35	57.67	42.12	90.36
	Image 3	/	/	67.95	51.45	92.84	86.64	/	/	80.40	69.05	95.64
	Image 4	/	/	51.00	34.23	89.86	81.59	/	/	70.43	57.91	95.91
	All images	0	0	47.62	32.30	79.66	67.80	68.72	52.35	65.337	50.82	92.58
Rural	Image 5	90.43	82.53	89.68	81.30	85.86	75.22	84.84	73.66	87.70	78.17	86.48
	Image 6	91.13	83.71	89.70	81.33	86.79	76.67	86.65	76.44	88.57	79.54	87.43
	Image 7	89.73	81.37	88.01	78.59	86.30	75.91	85.89	75.28	87.48	77.79	88.13
	Image 8	80.86	67.86	80.05	66.73	81.63	68.97	80.95	67.99	80.87	67.89	82.27
	All images	88.04	78.87	86.86	76.99	85.15	74.19	84.58	73.34	86.16	75.85	86.08

(b)

Region	Image	Cultivated land		Grassland		Forest		Aquatic vegetation		Mean F1 score	Mean IOU	OA
		F1	IOU	F1	IOU	F1	IOU	F1	IOU			
City	Image 1	16.53	9.01	18.22	10.02	63.32	46.33	/	/	32.69	21.79	87.02
	Image 2	15.67	8.50	13.59	7.29	67.49	50.93	67.28	50.70	41.01	29.36	89.79
	Image 3	/	/	12.44	6.63	90.27	82.27	/	/	51.36	44.45	94.88
	Image 4	/	/	14.94	8.07	83.56	71.77	/	/	49.25	39.92	93.90
	All images	16.51	8.76	14.80	8.00	76.16	62.83	67.28	50.70	43.58	33.88	91.40
Rural	Image 5	89.05	80.26	87.80	78.26	79.20	65.56	78.07	64.02	83.53	72.03	78.49
	Image 6	86.19	75.74	81.89	69.33	77.21	62.87	77.32	63.03	80.65	67.74	77.90
	Image 7	86.71	76.54	84.44	70.07	80.99	68.05	80.68	67.61	83.21	70.57	82.60
	Image 8	72.08	56.35	70.97	55.00	61.11	44.00	60.25	43.11	66.10	49.62	61.16
	All images	83.51	72.22	81.28	68.17	74.63	60.12	74.08	59.44	78.37	70.11	75.04

(c)

证明本文方法在高分辨率遥感影像植被分类提取上,不管是城市区域还是农村区域,均优于其他深度学习方法。同时,3种分类方法都表现出城市区域耕地与草地分类精度明显低于农村区域耕地与草地的分类精度,而林地和水生植被城乡差异较小的特点,这与本文方法得出的结论一致。

4.3 普适性验证

为了测试本文提出方法在其他地区以及其他传感器遥感影像中的普适性,选取高分二号北京地区以及高分六号合肥地区的遥感影像进行测试,分辨率为 1 m 和 2 m,均包括城市以及农村区域,分类提取结果如图 10 所示。

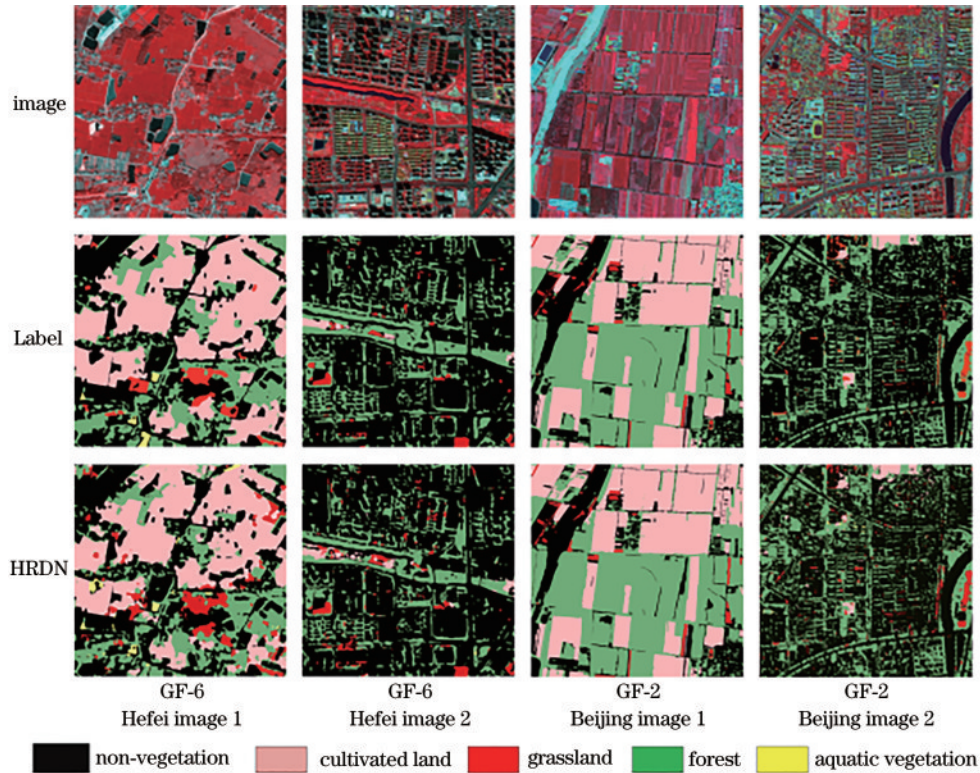


图 10 提出方法植被分类提取结果图

Fig. 10 Result map of vegetation classification and extraction by proposed method

从图 10 和表 6 中可以看出,草地整体分类精度较低,林地分类精度较高,这与前文得到的结论一致,说明本文提出方法不管在不同地区还是不同传感器上,

影像的测试结果与目视解译结果吻合度较高,说明提出方法对于不同地区、不同传感器都有良好的适用性。

表 6 提出方法植被分类提取精度

Table 6 Extraction accuracy of vegetation classification by proposed method

unit: %

Region	Cultivated land		Grassland		Forest		Aquatic vegetation		Mean F1 score	Mean IOU	OA	Kappa
	F1	IOU	F1	IOU	F1	IOU	F1	IOU				
GF-6 Hefei image 1	89.04	80.24	85.99	75.42	84.60	73.30	84.17	72.66	86.53	75.41	88.42	82.97
GF-6 Hefei image 2	59.79	42.64	62.56	45.51	84.22	72.74	84.17	72.67	72.69	58.39	93.55	84.14
GF-2 Beijing image 1	89.08	80.31	86.63	76.41	88.89	80.00	88.64	79.60	88.31	79.08	88.95	82.78
GF-2 Beijing image 2	71.40	55.52	64.89	48.03	85.82	75.17	85.71	75.00	76.95	63.43	92.41	83.32

5 结 论

本文提出适用于植被分类的网络 HRDN,该方法结合了高分辨率遥感影像原始光谱特征及其 NDVI,

主要采用并行的网络结构,并引入了密集连接模块与空洞空间金字塔池化模块,既增强不同植被信息提取能力,也获取了植被的多尺度信息,利用提出方法对高分 2 号遥感影像进行植被分类提取,城市区域的 OA

达到 96.73%, F1 得分为 82.14%, IOU 为 67.65%, 农村区域的 OA 为 91.35%, F1 得分为 90.28%, IOU 为 82.41%, 并与不加 NDVI 的 HRDN 进行对比, 验证了加入 NDVI 的有效性。将提出方法与 Deeplab-V3+、BiseNet、DCCN 3 种深度学习方法分类结果进行对比, 实验结果证明提出方法分类效果优于其他网络。此外, 为了验证提出方法的适用性, 除了对合肥地区高分 2 号遥感影像中不同植被类型进行提取, 还对高分 2 号北京的遥感影像以及高分 6 号合肥遥感影像进行植被分类, 得到了较高的分类精度, 证明了提出方法在不同传感器、不同地区均有良好的适用性。故该方法能在保证较高精度的情况下有效区分各植被类型, 在城市绿地规划、农村基本农田监管等方面具有一定的应用价值。

参 考 文 献

- [1] Nunes A N, de Almeida A C, Coelho C O A. Impacts of land use and cover type on runoff and soil erosion in a marginal area of Portugal[J]. *Applied Geography*, 2011, 31(2): 687-699.
- [2] Li L, Wen Q, Wang B, et al. Water body extraction from high-resolution remote sensing images based on scaling EfficientNets[J]. *Journal of Physics: Conference Series*, 2021, 1894(1): 012100.
- [3] 张影. 卫星高光谱遥感农作物精细分类研究[D]. 北京: 中国农业科学院, 2021.
Zhang Y. Fine classification of crops using satellite hyperspectral remote sensing imagery[D]. Beijing: Chinese Academy of Agricultural Sciences, 2021.
- [4] 史文旭, 鲍佳慧, 姚宇. 基于深度学习的遥感图像目标检测与识别[J]. *计算机应用*, 2020, 40(12): 3558-3562.
Shi W X, Bao J H, Yao Y. Remote sensing image target detection and identification based on deep learning[J]. *Journal of Computer Applications*, 2020, 40(12): 3558-3562.
- [5] 刘鸿雁, 蒋子涵, 戴景钰, 等. 岩石裂隙决定喀斯特关键带地表木本与草本植物覆盖[J]. *中国科学: 地球科学*, 2019, 49(12): 1974-1981.
Liu H Y, Jiang Z H, Dai J Y, et al. Rock crevices determine woody and herbaceous plant cover in the Karst critical zone[J]. *Scientia Sinica (Terrae)*, 2019, 49(12): 1974-1981.
- [6] 韩林果. 基于高分一号卫星影像的冬小麦种植面积提取方法研究[D]. 开封: 河南大学, 2019.
Han L G. Research on winter wheat planting area extraction method based on GF-1 image[D]. Kaifeng: Henan University, 2019.
- [7] 杨烁. 基于 Landsat 数据的大兴安岭地区主要树种分类及时空变化研究[D]. 哈尔滨: 哈尔滨师范大学, 2020.
Yang S. Study on the classification and spatial and temporal changes of main tree species in the greater Xing'an mountains based on Landsat data[D]. Harbin: Harbin Normal University, 2020.
- [8] 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.
- [9] 南亚飞, 张云蕾, 朱芮. 基于核空间优化支持向量机的合作频谱感知算法[J]. *南开大学学报(自然科学版)*, 2021, 54(3): 8-14.
Nan Y F, Zhang Y L, Zhu R. Cooperative spectrum sensing algorithm based on kernel space optimization support vector machine[J]. *Acta Scientiarum Naturalium Universitatis Nankaiensis*, 2021, 54(3): 8-14.
- [10] 邢晓语, 杨秀春, 徐斌, 等. 基于随机森林算法的草原地上生物量遥感估算方法研究[J]. *地球信息科学学报*, 2021, 23(7): 1312-1324.
Xing X Y, Yang X C, Xu B, et al. Remote sensing estimation of grassland aboveground biomass based on random forest[J]. *Journal of Geo-Information Science*, 2021, 23(7): 1312-1324.
- [11] 谷晓天, 高小红, 马慧娟, 等. 复杂地形区土地利用/土地覆被分类机器学习方法比较研究[J]. *遥感技术与应用*, 2019, 34(1): 57-67.
Gu X T, Gao X H, Ma H J, et al. Comparison of machine learning methods for land use/land cover classification in the complicated terrain regions[J]. *Remote Sensing Technology and Application*, 2019, 34(1): 57-67.
- [12] 刘颖, 杨轲. 基于深度集成学习的类极度不平衡数据信用欺诈检测算法[J]. *计算机研究与发展*, 2021, 58(3): 539-547.
Liu Y, Yang K. Credit fraud detection for extremely imbalanced data based on ensembled deep learning[J]. *Journal of Computer Research and Development*, 2021, 58(3): 539-547.
- [13] Ozdarici-Ok A, Ok A, Schindler K. Mapping of agricultural crops from single high-resolution multispectral images: data-driven smoothing vs. parcel-based smoothing [J]. *Remote Sensing*, 2015, 7(5): 5611-5638.
- [14] 亢超, 李文祥, 黄岫, 等. 基于深度学习的主动光学校正算法研究[J]. *光学学报*, 2021, 41(6): 0611004.
Kang C, Li W X, Huang S, et al. Research on active optical correction algorithm based on deep learning[J]. *Acta Optica Sinica*, 2021, 41(6): 0611004.
- [15] 庄秋实, 何泽文, 张春旭, 等. 基于深度学习的透过散射介质偏振识别[J]. *光学学报*, 2021, 41(22): 2229001.
Zhuang Q S, He Z W, Zhang C X, et al. Polarization recognition through scattering media based on deep-learning[J]. *Acta Optica Sinica*, 2021, 41(22): 2229001.
- [16] 张磊, 徐孝彬, 曹晨飞, 等. 基于动态特征剔除的图像与点云融合的机器人位姿估计方法[J]. *中国激光*, 2022, 49(6): 0610001.
Zhang L, Xu X B, Cao C F, et al. Robot pose estimation method based on image and point cloud fusion with dynamic feature elimination[J]. *Chinese Journal of Lasers*, 2022, 49(6): 0610001.
- [17] Huang H S, Lan Y B, Deng J Z, et al. A semantic labeling approach for accurate weed mapping of high

- resolution UAV imagery[J]. *Sensors*, 2018, 18(7): 2113.
- [18] Yang M D, Tseng H H, Hsu Y C, et al. Semantic segmentation using deep learning with vegetation indices for rice lodging identification in multi-date UAV visible images[J]. *Remote Sensing*, 2020, 12(4): 633.
- [19] 马海艺, 张天怡, 代沁伶, 等. 基于 I-FCN 模型的城市高分辨率遥感影像植被信息提取[J]. *西南林业大学学报(自然科学)*, 2019, 39(3): 117-123.
- Ma H Y, Zhang T Y, Dai Q L, et al. Extracting urban vegetation from high-resolution remote sensing image based on I-FCN model[J]. *Journal of Southwest Forestry University (Natural Sciences)*, 2019, 39(3): 117-123.
- [20] Alhassan V, Henry C, Ramanna S, et al. A deep learning framework for land-use/land-cover mapping and analysis using multispectral satellite imagery[J]. *Neural Computing and Applications*, 2020, 32(12): 8529-8544.
- [21] 林锦涵, 陈芸芝, 汪小钦. 基于绿视率的福州市鼓楼区道路绿化水平评价[J]. *中国城市林业*, 2021, 19(3): 73-77, 84.
- Lin J H, Chen Y Z, Wang X Q. Road greening level evaluation of Gulou district in Fuzhou based on visible green index[J]. *Journal of Chinese Urban Forestry*, 2021, 19(3): 73-77, 84.
- [22] Gui Y Y, Li W, Wang Y N, et al. Woodland detection using most-sure strategy to fuse segmentation results of deep learning[C]//IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium, July 28-August 2, 2019, Yokohama, Japan. New York: IEEE Press, 2019: 6724-6727.
- [23] Morales G, Kemper G, Sevillano G, et al. Automatic segmentation of *Mauritia flexuosa* in unmanned aerial vehicle (UAV) imagery using deep learning[J]. *Forests*, 2018, 9(12): 736.
- [24] Zhu Q H. ACDNet with ASPP for camouflaged object detection[J]. *Journal of Physics: Conference Series*, 2021, 1982(1): 012082.
- [25] Yao X D, Yang H, Wu Y L, et al. Land use classification of the deep convolutional neural network method reducing the loss of spatial features[J]. *Sensors*, 2019, 19(12): 2792.
- [26] Liu R, Lehman J, Molino P, et al. An intriguing failing of convolutional neural networks and the CoordConv solution[EB/OL]. (2018-07-09) [2021-04-07]. <https://arxiv.org/abs/1807.03247>.
- [27] Sun K, Xiao B, Liu D, et al. Deep high-resolution representation learning for human pose estimation [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). arXiv, 2019.
- [28] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11211: 833-851.
- [29] Wu Y X, He K M. Group normalization[J]. *International Journal of Computer Vision*, 2020, 128(3): 742-755.