

文章编号: 2095-4980(2021)01-0132-06

基于遥感影像和神经网络的城市用地功能分类

刘美¹, 卿粼波^{*1}, 韩龙玫², 许盛宇¹

(1.四川大学 电子信息学院, 四川 成都 610065; 2.成都市规划设计研究院 信息中心, 四川 成都 610065)

摘要: 城市用地功能分类的准确识别对精准把握城市现状、优化城市空间结构有重要意义。基于此, 利用高分辨力遥感影像, 提出一种针对中国城市用地功能分类的模型。设计一种多分辨率特征融合的卷积神经网络识别遥感影像中的特定功能区; 针对中国城市功能区分布的特点, 建立一个用于城市用地功能分类的新数据集。实验显示, 本文算法在6种用地功能类型上的分类精确度达88%, 表明算法对城市用地功能分类识别具有较高的准确性。最后, 通过对北京部分主要城区的案例研究, 验证了所提出的模型在城市规划相关领域提供数据支持的价值和有效性。

关键词: 遥感影像; 用地功能分类; 神经网络; 城市规划

中图分类号: TN919.81

文献标志码: A

doi: 10.11805/TKYDA2020260

Urban land use classification based on remote sensing images and neural network

LIU Mei¹, QING Linbo^{*1}, HAN Longmei², XU Shengyu¹

(1.School of Electronic Information Engineering, Sichuan University, Chengdu Sichuan 610065, China;

2.Chengdu Institute of Planning & Design, Information Center, Chengdu Sichuan 610065, China)

Abstract: Urban land use classification is of great significance for capturing current situation of cities accurately and optimizing urban spatial structure. An urban land use classification model specifically for China is proposed by using remote sensing images. Firstly, a multi-resolution feature fusion convolution neural network is designed to recognize urban land use types. Besides, according to the distribution characteristics of urban functional areas in China, a new dataset for the urban land use classification is proposed. Experimental results show that the proposed work can reach 88% accuracy on six urban land use types, which validates the effectiveness of the algorithm in the classification of urban land use. Finally, a case study for part of Beijing's main urban districts demonstrates the value and effectiveness of the proposed model for providing data support in the field of urban planning.

Keywords: remote sensing images; land use classification; neural network; urban planning

城市的紧凑度和多样性是我国经济社会可持续发展的两大核心要素^[1]。完善城市功能布局, 有助于形成优良的城市紧凑度。因此, 城市用地功能的布局一直是城市规划的重点。由于城市的快速发展, 实际用地功能情况也在不断地改变。传统获取城市功能区的方法大多采用问卷调查、专家评判等。该方法对时间和人力的要求极高, 且难以及时动态地更新功能区的分布情况^[2]。如何快速获取城市功能区的分布情况并及时对其进行动态更新, 是我国城市研究的重点之一。

近年来, 遥感技术的发展日趋成熟, 并已广泛用于各种场景, 如土地利用和土地覆被变化检测、灾害监测、交通管理^[3-5]等。除此之外, 遥感图片在城市功能区的识别方面也体现出巨大的应用价值。王彩艳^[6]等以分辨率5.8 m的资源三号卫星遥感影像为数据源, 采用面向对象的分类方法对北京市四环以内的区域进行建设用地的提取。如今的遥感影像分辨率可达到0.6 m甚至是0.3 m, 该方法所采用的数据源分辨率已经无法精细化地识别出

收稿日期: 2020-06-03; 修回日期: 2020-07-04

基金项目: 国家自然科学基金资助项目(61871278); 四川省科技计划资助项目(2018HH0143); 四川省教育厅科研资助项目(18ZB0355)

作者简介: 刘美(1997-), 女, 在读硕士研究生, 主要研究方向为多媒体通信、图像处理与机器学习。email:2018222050114@stu.scu.edu.cn

*通信作者: 卿粼波 email:qing_lb@scu.edu.cn

城市用地类型。李娅^[7]等结合遥感影像、兴趣点以及路网数据,对北京西城区的部分区域进行功能区的识别。上述方法均是对特定的城市进行研究,没有考虑到城市与城市之间存在的差异性,具有一定的局限性。

深度学习近年来发展迅速,在图像分类^[8]、社交感知^[9]、人脸对齐^[10]等方面发挥着不可或缺的作用。与传统方法相比,卷积神经网络以其独特的结构和运作模式,可以学习到更加丰富的图像特征,因此,研究人员将卷积神经网络广泛用于场景分类^[11-13]。但现有的场景分类数据集,如 UC Merced Land Use^[14], WHU-RS19^[15], NWPU-RESISC45^[16]等,其类别中大部分包含沙滩、森林、沙漠等,适用性较差,无法直接用于中国城市的用地功能分类。

考虑到上述局限性,本文旨在通过深度学习技术,结合中国城市用地功能分布的特点,提出一种基于遥感影像的城市用地功能分类方法。其中,基于开放、免费的遥感影像数据,构建一个高分辨力且具备中国城市功能区分布特点的新数据集 SCU-AISC6,并设计一个多分辨力特征融合卷积神经网络来有效识别功能区的类型。实验结果表明,该模型在公开数据集 SIRI-WHU^[17]和 SCU-AISC6 数据集上均表现良好。

1 数据和方法

1.1 数据集介绍

为识别中国城市的用地功能类型,针对中国城市功能区的分布特点,提出了 SCU-AISC6 数据集。对于用地功能的类型划分,本文基于 GB50137-2011《城市用地分类与规划建设用地标准》中的城市建设用地分类标准,并综合考虑城市用地功能类型的普遍性和数据获取的可行性,选取了 6 种建设用地类型进行研究,分别是:居住用地、公共管理与公共服务用地、商业服务业设施用地、工业用地、道路与交通设施用地以及绿地与广场用地。数据集所有的图片都收集于百度地图,覆盖范围包括北京、上海和南京等中国的 20 多个城市,共包含 17 831 张遥感影像。其中,每个类包含约 2 900 张图片,空间分辨力为 0.6 m,每张图片为 200×200 像素。以表 1 中的商业服务业设施用地为例,对数据集的用地功能类别进行详细的阐述。商业服务业设施用地分为商业设施用地以及商务住宅两大类。其中商业设施用地又可分为餐饮服务、购物服务、住宿服务、金融保险服务用地;商务住宅主要包含商务写字楼。

表 1 功能区详细类别
Table1 Detailed classification of functional areas

first class	second class	third class
residential	—	residential areas
administration and public service	administrative land	party and government organizations, public institution
	cultural facilities land	library, art museum, science and technology museum
	education and research land	colleges and universities, middle schools, primary schools
	medical and sanitary land	general hospital, specialized hospital
commercial and business facilities	commercial facility land	commercial and hotel, catering and other services land
	commercial neighborhood	business office building
industrial	—	factory, industrial zone
road,street and transportation	traffic hinge land	airport, railway station, bus station
green space and square	public park	park, botanical garden
	scenic spots land	scenic area, national park

1.2 多分辨力特征融合网络

由于遥感图片分辨力不同,图像中的目标尺寸大小不等。在遥感影像中,一些建筑物小而拥挤,而一些影像中只有一幢建筑物。受 HRNet^[18]的启发,本文提出一种多分辨力特征融合的卷积神经网络,解决遥感图像中分辨力不同的问题,获得了更好的性能。

与大多数现有的遥感图像分类中的特征融合算法不同,本文的多分辨力特征融合算法是将高层次的语义特征与低层次的语义特征进行融合,而不仅是融合纹理、形状等低阶特征^[19];此外,本文的多分辨力特征融合算法在融合高低层次特征时采用并行方式,而非级联方式^[20]。如图 1 所示,网络的第一阶段分别提取低、高层次的特征,第二阶段融合低、高层次特征。具体地:首先图像的初始特征通过 2 个步长为 2,卷积核为 3×3 大小的卷积层提取。图 1 中的 res_block 1 由 2 个 bottlenecks^[21]组成, bottleneck 可以在特征降维的情况下学习特征,有效减少全连接的数量。然后,特征由 2 个分支进行传输。图 1 中的 res_block 2 和 res_block 3 由 2 个残差单元组

成, 每个残差单元由 2 个 3×3 大小的卷积核组成, 残差单元可以通过逆向更新梯度^[22]来解决梯度消失的问题, 更容易优化。第二个分支中的特征图的分辨力是第一个分支的一半, 为了融合不同分辨力的特征图, 通过反卷积来提高低分辨力特征图的分辨力。反卷积可以视为普通卷积的逆向过程, 其根本目的是放大特征图。反卷积的操作过程可以用以下函数来表示:

$$Y_{out} = U_{s,p}(Y_{in}, W) + b \quad (1)$$

式中: Y_{out} 为输入特征图反卷积之后的结果; U 为反卷积函数, 下标 s, p 分别表示反卷积操作中的步长和边界填充; Y_{in} 为输入特征图; W 为反卷积核的大小; b 为偏置项。

融合后的特征图送入 6×6 的平均池化层, 最后再通过一个全连接层和一个 softmax 层得到网络最终的预测结果, 记为 $h^i (i=1, 2, \dots, 6)$, h^i 表示输入的每一张遥感图片对应属于第 i 类的概率。根据 h^i , 可以得到第 j 张遥感图片最终的预测类别值:

$$h_j = \max(h^1, h^2, \dots, h^6) \quad (2)$$

在多分辨力特征融合网络中, 卷积核都是 3×3 和 1×1 的大小。其中, 下采样操作是通过 3×3 大小、步长为 2 的卷积完成。而 1×1 的卷积则用来改变特征图的通道大小。

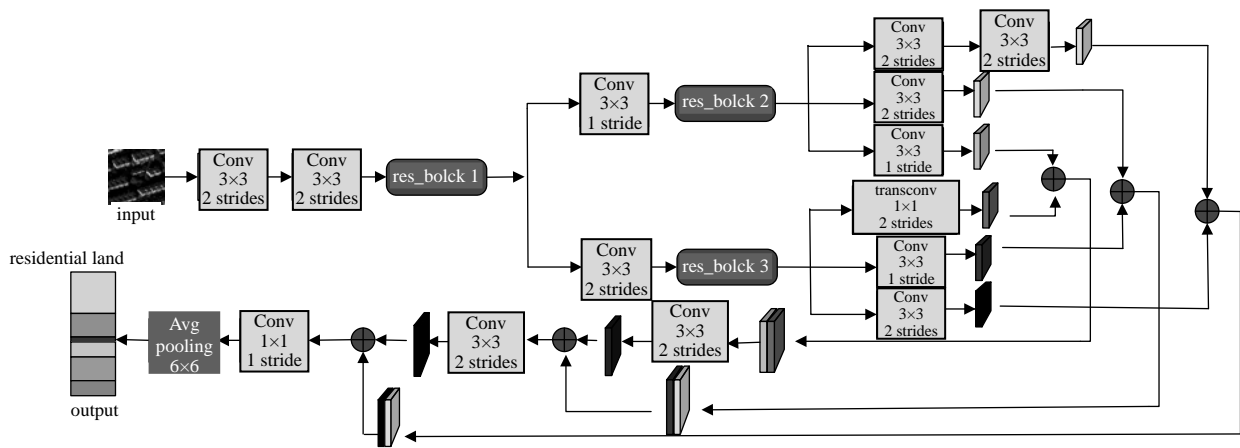


Fig.1 Multi-resolution feature fusion network
图 1 多分辨力特征融合网络

2 实验结果分析

2.1 实验数据及配置

实验在 64 位 Ubuntu 系统环境下进行, 深度学习框架选择 TensorFlow, 处理器为 Intel(R) Xeon(R) E5-2678v3, 128 G 内存, 显卡为一张显存 11 GB 的 NVIDIA GeForce RTX2080Ti。

为与其他算法作对比, 在公开数据集 SIRI-WHU^[17]和本文数据集 SCU-AISC6 上开展实验, 选取总正确率 (Overall Accuracy, OA) 和混淆矩阵作为评估模型有效性的指标。OA 可以反映模型对所有类的整体分类性能, 混淆矩阵可以直观方便地观察到每一类具体的预测结果。选择 Adam 优化器, batch size 和学习率通过多次实验得出最佳的设置为 64 和 10^{-3} 。所有的卷积神经网络 (Convolutional Neural Networks, CNN) 模型都训练到收敛为止。在 SIRI-WHU 实验中, 随机挑选其中 80% 的图片用来训练, 并对训练数据进行一定的数据增强, 其余的 20% 用作测试, 此种数据划分比例参照了相关的遥感图片场景分类文献^[13]。在 SCU-AISC6 实验中, 将数据集按照 8:1:1 的比例随机分为训练集、验证集和测试集。

2.2 实验结果及分析

表 2 和表 3 分别为公开数据集 SIRI-WHU 和本文数据集 SCU-AISC6 的对比实验。表 2 中 ours1 表示只融合所提网络第一个小分支的结果, ours2 表示融合网络第二、三个小分支的结果, ours 表示融合所有小分支的结果。由表 2 可以看出, 所提网络结构融合所有小分支的准确度最高。除此之外, 由表 2 和表 3 可以看出, 本文算法的精确度无论是在公开数据集还是在新的数据集上均优于其他几种算法。

表 2 SIRI-WHU 对比结果

Table2 SIRI-WHU results	
method	OA/%
BoVW ^[13]	73.93
S-UFL ^[23]	74.84
SPM-SIFT ^[13]	80.26
CCNN ^[13]	88.26
SRSCNN-NV ^[13]	91.06
ours1	89.38
ours2	90.42
ours	92.92

表 3 SCU-AISC6 对比结果

Table3 SCU-AISC6 results	
method	OA/%
AlexNet ^[24]	71.32
VGG16 ^[25]	74.53
ResNet-101 ^[21]	81.29
ResNet-50 ^[21]	83.47
Inception_v3 ^[26]	86.26
ours	88.17

图 2 和图 3 分别为本文算法在 SIRI-WHU 和 SCU-AISC6 两个数据集上的混淆矩阵。从图 2 中可以看出, 算法在公开数据集的大多数类别上分类性能良好, pond 类分类效果最差, 为 78%, 其被误判为 river 类的概率最高。从图 3 可以看出, 除商业服务业设施用地外, 其他类别的识别准确率都达到 80% 以上, 绿地与广场用地的识别准确率最高, 达到了 95%。而商业服务业设施用地被误判为工业用地和绿地与广场用地的概率最高。从图 4 中可以看出, 数据集中商业类子类别下的部分商业街图片和工业用地图片具有相似的外观; 图 5 为商业类子类别下的部分商务写字楼图片与绿地类图片具有相似的外观, 这是导致误判概率高的原因之一。




Fig.2 Confusion matrix on SIRI-WHU dataset
图 2 SIRI-WHU 上的混淆矩阵



Fig.4 Images labelled industrial, commercial
图 4 工业类, 商业类图片




Fig.3 Confusion matrix on SCU-AISC6 dataset
图 3 SCU-AISC6 上的混淆矩阵



Fig.5 Images labelled green space, commercial
图 5 绿地类, 商业类图片

3 案例研究

为体现本文所提方法的应用价值, 选择北京主城区的一个区域进行研究, 所选区域的遥感影像大小为 7 000 × 7 000 像素, 空间分辨力为 0.6 m(图 6(a)), 包含各类酒店、购物中心、公园、社区等, 拥有多种用地功能类型。首先获取该地区的遥感影像, 将图像分割成 200 × 200 像素大小的网格, 共得到 1 225 个网格图像, 并将其作为测试集输入到训练好的模型中进行预测, 选择来自百度地图的 POI 标签作为真值, 生成该区域对应的用地功能分布图, 由于 POI 数据是以“点”的形式存在, 无法映射成面进行真值的展示, 故本文没有进行 POI 真

值图的展示。如图 6(b)所示,总体上,该区域以住宅为主,其中,图 6(a)突出显示的块中玉渊潭公园和莲花池公园被识别为绿地和广场用地,北京西站被识别为道路与交通设施用地、三里河小区被识别为居住用地,泰康国际大厦以及百盛购物中心被识别为商业服务业设施用地,与实际相符,识别结果准确度较高。这表明本文提出的基于遥感图像进行城市用地功能分类的方法是有效的,并可以为城市规划提供一定的参考。

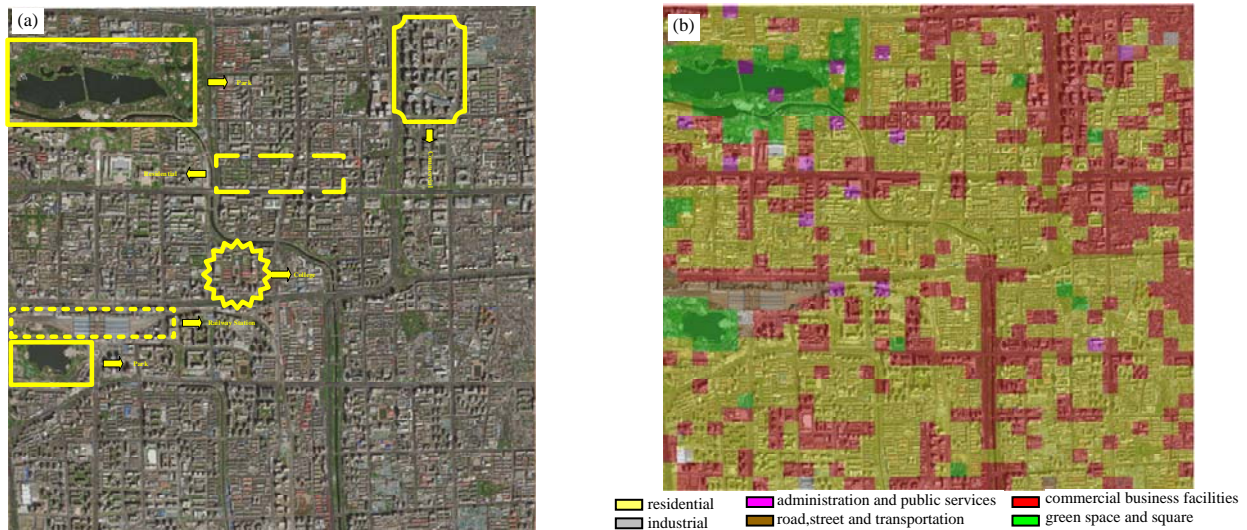


Fig.6 (a) original image; (b) classified image respectively

图 6 (a) 原始遥感影像; (b) 分类后的图片

4 结论

为适应中国城市功能区的分布特点,建立了一个新的数据集,并设计了一个多分辨率融合的卷积神经网络来识别中国城市的用地功能类型。选取北京市主城区某一区域作为案例研究区域,并与从百度地图中检索到的 POI 标签进行对比分析。结果表明,该方法的识别结果与实际情况基本一致,验证了本文方法的有效性。本文所提出的方法可以为城市功能布局、空间结构优化等提供有力的数据支撑,与传统方法相比,节省时间,易于实施。

在未来的工作中,将考虑扩大数据集,以覆盖中国所有城市。部分用地功能的遥感图像具有相似外观导致识别结果有误,可以结合手机信令、新浪微博签到等其他数据源,进一步提高识别的准确性。

参考文献:

- [1] 仇保兴. 紧凑度与多样性(2.0 版)——中国城市可持续发展的两大核心要素[J]. 城市发展研究, 2012,19(11):1-12. (QIU Baoxing. Compactness and diversity(version 2.0):two core elements of sustainable urban development in China[J]. Urban Studies, 2012,19(11):1-12.)
- [2] 彭正洪,孙志豪,程青,等. 利用时序手机通话数据识别城市用地功能[J]. 武汉大学学报(信息科学版), 2018,43(9):1399-1407,1437. (PENG Zhenghong,SUN Zhihao,CHENG Qing,et al. Identification of urban land use using time-series mobile phone call data[J]. Geomatics and Information Science of Wuhan University, 2018,43(9):1399-1407,1437.)
- [3] XIAO J,SHEN Y,GE J,et al. Evaluating urban expansion and land use change in Shijiazhuang,China,by using GIS and remote sensing[J]. Landscape and Urban Planning, 2006,75(1):69-80.
- [4] FINGAS M,BROWN C. Review of oil spill remote sensing[J]. Marine Pollution Bulletin, 2014,83(1):9-23.
- [5] PALUBINSKAS G,KURZ F,REINARTZ P. Detection of traffic congestion in optical remote sensing imagery[C]// 2008 IEEE International Geoscience & Remote Sensing Symposium. Boston,MA,USA:IEEE, 2008:426-429.
- [6] 王彩艳,王媛玲,王介勇,等. 基于面向对象的北京市区城市内部用地信息提取[J]. 自然资源学报, 2015,30(4):705-714. (WANG Caiyan,WANG Ailing,WANG Jieyong,et al. Land use information extraction in the inner city of Beijing based on object-oriented classification method[J]. Journal of Natural Resources, 2015,30(4):705-714.)
- [7] 李娅,刘亚岚,任玉环,等. 城市功能区语义信息挖掘与遥感分类[J]. 中国科学院大学学报, 2019,36(1):56-63. (LI Ya, LIU Yalan,REN Yuhuan,et al. Semantic information mining and remote sensing classification of urban functional areas[J]. Journal of University of Chinese Academy of Sciences, 2019,36(1):56-63.)

- [8] DURAND T,MEHRASA N,MORI G,et al. Learning a deep ConvNet for multi-label classification with partial labels[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach,CA,USA:IEEE, 2019:647–657.
- [9] 王磊,高宸,周蓓,等. 基于深度学习与社交感知的地点推荐[J]. 太赫兹科学与电子信息学报, 2019,17(3):502–508. (WANG Lei,GAO Chen,ZHOU Bei,et al. Deep learning based social-aware location recommendation[J]. Journal of Terahertz Science and Electronic Information Technology, 2019,17(3):502–508.)
- [10] WU W,QIAN C,YANG S,et al. Look at boundary:a boundary-aware face alignment algorithm[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City,UT,USA:IEEE, 2018:2129–2138.
- [11] ZHANG W,TANG P,ZHAO L. Remote sensing image scene classification using CNN–capsnet[J]. Remote Sensing, 2019, 11(5):494.
- [12] YU Y,LIU F. A two-stream deep fusion framework for high-resolution aerial scene classification[J]. Computational Intelligence and Neuroscience, 2018(4–5):1–13.
- [13] LIU Y,ZHONG Y,FEI F,et al. Scene classification based on a deep random-scale stretched convolutional neural network[J]. Remote Sensing, 2018,10(3):444.
- [14] YANG Y,NEWSAM S. B Bag-of-visual-words and spatial extensions for land-use classification[C]// 18th ACM SIGSPATIAL International Symposium on Advances in Geographic Information Systems. San Jose,CA,USA:[s.n.], 2010:270–279.
- [15] DAI D,YANG W. Satellite image classification via two-layer sparse coding with biased image representation[J]. IEEE Geoscience and Remote Sensing Letters, 2011,8(1):173–176.
- [16] CHENG G,HAN J,LU X. Remote sensing image scene classification: benchmark and state of the art[J]. Proceedings of IEEE, 2017,105(10):1865–1883.
- [17] ZHU Q,ZHONG Y,ZHAO B,et al. Bag-of-visual-words scene classifier with local and global features for high spatial resolution remote sensing imagery[J]. IEEE Geoscience and Remote Sensing Letters, 2016,13(6):747–751.
- [18] SUN K,ZHAO Y,JIANG B,et al. High-resolution representations for labeling pixels and regions[DB/OL]. arXiv:1904. 04514v1, 2019.
- [19] 孟庆祥,段学琳. 基于 DCNN 的高分辨率遥感影像场景分类[J]. 华中师范大学学报(自然科学版), 2019,53(4):568–574. (MENG Qingxiang,DUAN Xuelin. High resolution remote sensing image scene classification based on DCNN[J]. Journal of Central China Normal University(Natural Science Edition), 2019,53(4):568–574.)
- [20] 张军,张敏,郝小可,等. 基于多尺度特征融合的中分辨率遥感场景分类算法[J]. 河北大学学报(自然科学版), 2019, 39(6):666–672. (ZHANG Jun,ZHANG Min,HAO Xiaoke,et al. Moderate resolution remote sensing scene classification method based on multi-scale feature fusion[J]. Journal of Hebei University(Natural Science Edition), 2019,39(6):666–672.)
- [21] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas,NV,USA:IEEE, 2016:770–778.
- [22] HE K,ZHANG X,REN S,et al. Identity mappings in deep residual networks[C]// European Conference on Computer Vision, Amsterdam:Springer, 2016:630–645.
- [23] ZHANG F,DU B,ZHANG L,et al. Saliency-guided unsupervised feature learning for scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015,53(4):2175–2184.
- [24] KRIZHEVSKY A,SUTSKEVER I,HINTON G E,et al. Imagenet classification with deep convolutional neural networks[C]// Proceedings of the 25th International Conference on Neural Information Processing Systems, 2012:1097–1105.
- [25] SIMONYAN K,ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus,Ohio,USA:IEEE, 2014:1–14.
- [26] SZEGEDY C,VANHOUCKE V,IOFFE S,et al. Rethinking the inception architecture for computer vision[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas,NV,USA:IEEE, 2016:2818–2826.