

基于多尺度扩张卷积神经网络的城中村遥感识别

冯权泷^{1,2} 陈泊安¹ 牛博文¹ 任 燕^{1,3} 王 莹⁴ 刘建涛⁵

(1. 中国农业大学土地科学与技术学院, 北京 100083; 2. 资源与环境信息系统国家重点实验室, 北京 100101;
3. 四川农业大学资源学院, 成都 625014; 4. 中国科学院城市环境研究所, 厦门 361021;
5. 山东建筑大学测绘地理信息学院, 济南 250101)

摘要: 城中村是我国快速城市化进程中的一个特殊产物, 通常存在人口密集、建筑私自改造等问题。开展城中村的识别和监测对城乡统筹规划以及精细化治理等具有重要意义。基于深度学习提出了一种新的城中村遥感识别模型, 该模型包括一个多尺度扩张卷积模块和一个非局部特征提取模块, 前者能够聚合多层次空间特征以适应城中村形状、尺度的变异性; 后者用于提取全局语义特征以提高城中村的类间可分性。选取北京市二环与六环之间的区域作为研究区, 实验结果表明本文模型取得了较好的识别效果, 总体精度可达 94.27%, Kappa 系数为 0.8839, 且效果优于传统模型。本文研究表明, 基于多尺度扩张卷积神经网络进行城中村遥感识别是可行且有效的, 可为城乡统筹规划提供精确的城中村空间分布数据。

关键词: 城中村; 场景识别; 扩张卷积神经网络; 深度学习

中图分类号: P283.8; TP75 文献标识码: A 文章编号: 1000-1298(2021)11-0181-09 OSID: 

Identification of Urban Villages from Remote Sensing Image Based on Multi-scale Dilated Convolutional Neural Network

FENG Quanlong^{1,2} CHEN Boan¹ NIU Bowen¹ REN Yan^{1,3} WANG Ying⁴ LIU Jiantao⁵

(1. College of Land Science and Technology, China Agricultural University, Beijing 100083, China
2. State Key Laboratory of Resources and Environmental Information System, Beijing 100101, China
3. College of Resources, Sichuan Agricultural University, Chengdu 625014, China
4. Institute of Urban Environment, Chinese Academy of Sciences, Xiamen 361021, China
5. School of Surveying and Geo-Informatics, Shandong Jianzhu University, Ji'nan 250101, China)

Abstract: Urban villages (UVs) belong to a special product of China's rapid urbanization process, which have similar properties to the informal settlements abroad. Specifically, UVs in China usually have a high population density due to the reconstruction of buildings, making it a big challenge in China's urban and rural sustainable development. Especially under the background of "promoting the new-type urbanization" issued by the government, timely and accurate identification of UVs is of great significance to both urban-rural planning and urban fine management. Researchers usually obtain the spatial information of UVs by field research in traditional studies, which is both laboursome and tedious. Remote sensing, on the other hand, has the merits of synoptic view, dynamic and fast screening of the earth surface, which has been recently applied in the recognition of UVs. Meanwhile, deep learning has shed new light on UVs' identification due to its capability in learning high-level abstract image features, however, it has been rarely documented in the mapping of UVs. Therefore, the objective was to propose a deep learning model for UVs' recognition from very high resolution (VHR) remote sensing images. In specific, the proposed model was a multi-scale dilated convolutional neural network (MD-CNN), which included a series of multi-scale dilated convolutions and a non-local feature extraction module. The former can aggregate multi-level spatial features to adapt to the variability of UVs' shapes and scales, while the latter extracted global semantic features to improve the inter-class divisibility. The experimental results in Beijing City showed that the proposed model achieved good performance with an overall

收稿日期: 2020-11-19 修回日期: 2021-01-19

基金项目: 国家重点研发计划项目(2018YFE0122700)、国家自然科学基金项目(42001367、42171113)和资源与环境信息系统国家重点实验室开放基金项目

作者简介: 冯权泷(1988—), 男, 副教授, 博士生导师, 主要从事机器、深度学习及在农业遥感中的应用研究, E-mail: fengql@cau.edu.cn

accuracy of 94.27% and a Kappa coefficient of 0.8839, which was better than that of several previous deep learning models such as VGG, ResNet and DenseNet. The research result demonstrated that by using the deep learning model, it was feasible and effective to accurately identify UVs from VHR remote sensing images, which could provide useful geo-spatial distribution of UVs for urban-rural planning.

Key words: urban villages; scene recognition; dilated convolution neural network; deep learning

0 引言

随着中国经济高速发展和城市化快速推动,原本位于城乡结合区域的中小型村庄不断被城市吸纳成为城市的组成部分^[1],并形成了具有中国城市化进程中特有的非正式聚居地形式——城中村^[2-3],其与国外的非正规城市聚落具有相似的性质^[4-7]。

作为我国城镇化变迁过程中的特殊区域,城中村是城市扩张中最有可能与城市融合的区域,也是加快城镇化建设步伐的关键区域^[8]。开展城中村的识别和监测对城乡统筹规划以及精细化治理等具有重要意义。

在以往的城中村识别研究中,研究人员一般从社会学、经济学等角度出发,通过实地调研来获取城中村相关信息^[9]。但城中村往往存在结构混乱、布局多样等特点,部分区域难以进入,增加了数据获取的难度。尤其当涉及大范围城中村研究时,地面调查方式较为费时费力,数据采集效率较低。

相比于实地调查,遥感具有宏观、动态、快速等特点,被广泛应用于场景分类^[10-15]以及农业温室地膜提取^[16]、作物分类识别^[17-18]等农业应用领域。在利用遥感技术识别和监测城中村方面,国内外学

者进行了一些研究^[9,19-23]。尽管深度学习被应用到城中村遥感识别领域,然而当前模型多以借鉴计算机视觉领域模型为主,没有针对城中村进行模型设计和优化。同时城中村所处环境景观格局复杂,城中村自身又存在形状、尺度的变异性,都增加了其识别的难度。为了解决上述问题,本文提出一种基于多尺度扩张卷积神经网络(Multi-scale dilated convolutional neural network, MD-CNN)的城中村识别模型。该模型由一系列多尺度扩张卷积模块和一个非局部特征提取模块组成,前者利用一系列具有不同扩张率的扩张卷积块提取多尺度特征,并以此描述城中村的尺度变化;后者基于非局部特征提取模块来获取高分辨率遥感图像上的远距离依赖关系,以学习全局特征和语义信息,并进一步增强类间可分性。

1 材料与方法

1.1 研究区

本文选取北京市作为研究区。北京市(图1)经纬度范围为115°25'~117°39'E,39°26'~41°N,位于华北平原北部,毗邻渤海,与天津市、河北省相接。全市包含16个区,总面积超过 $1.6 \times 10^4 \text{ km}^2$ 。至2019年底,常驻人口超过2100万人。

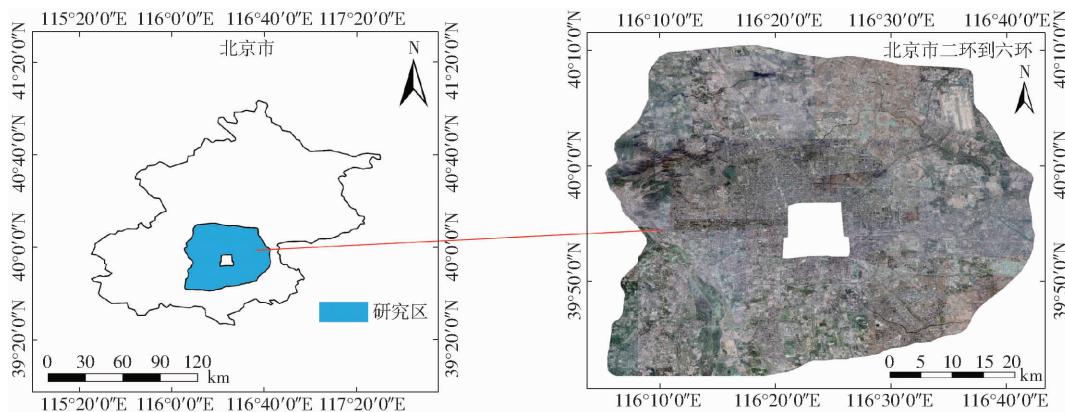


图1 研究区

Fig. 1 Map of research area

20世纪90年代开始,北京经济发展迅速,城市不断向外扩张,逐渐吸纳周围耕地、草地、村庄等区域,使得众多村庄、城乡结合部区域向城中村型居住地开始转化。

本文研究区为北京市二环到六环之间的区域,

因为二环内分布大量四合院,其形状纹理特征与城中村十分相似。通过目视解译可知,北京市的城中村主要出现在海淀区、石景山区以及近郊的昌平区、顺义区、通州区、大兴区等区域,分布方式以小聚集和零星散布为主。几乎所有城中村均存在建筑密

集、建筑材料多样、布局无规律等特征。

1.2 数据集

1.2.1 数据源

本文基于 Google Earth 平台获取研究区的 17 级遥感图像,空间分辨率约为 2.15 m,图像获取时间为 2019 年,包含红、绿、蓝 3 个波段。图像尺寸为 59 136 像素 \times 58 624 像素,实际地面尺寸约 127.1 km \times 126.4 km,区域内图像含云量较少,满足研究所需条件。



图 2 样本示例

Fig. 2 Sample examples

综合考虑遥感图像分辨率与城中村在图像上的空间特征后,本文的训练样本与测试样本尺寸均设置为 224 像素 \times 224 像素,在 Google Earth 17 级遥感数据下该样本能够覆盖约 0.23 km² 的地表范围,与研究区内大多数城中村具有较好的一致性,能够较好地表达城中村复杂的内部要素与外部形态。同时,224 像素 \times 224 像素为计算机视觉领域中常用的图像样本大小,便于与其他常见的分类模型进行精度对比。

2 城中村遥感识别模型

2.1 模型架构

图 3 给出了本文所设计的城中村识别模型 MD-CNN 的结构图。可以看出,MD-CNN 的输入是 224 像素 \times 224 像素的遥感图像块,模型输出是该图像块对应的类别,共包括城中村和其他两个类

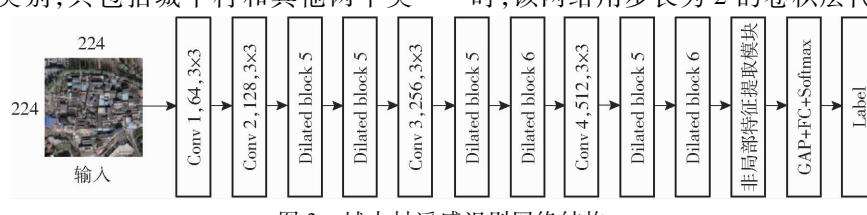


Fig. 3 Network structure of remote sensing identification of UVs

1.2.2 样本采集与划分

通过人工目视解译,在研究区随机对典型城中村区域与其他非城中村区域进行样本采集,共采集 1 924 幅图像样本,其中城中村样本 800 幅,非城中村样本 1 124 幅。按照 4:1 划分训练集和测试集,其中训练集用于模型训练,测试集用于模型精度验证。训练集与测试集无区域重叠。图 2 为样本集中城中村区域和非城中村区域样本的典型示例。



(a) 城中村区域



(b) 非城中村区域

别。具体而言,MD-CNN 主要包括以下 3 部分:

(1) 多尺度扩张卷积模块 (Dilated block): 用于提高模型对于城中村尺度变异的适应性和鲁棒性。

(2) 非局部特征提取模块: 用于进一步提取城中村的全局特征和上下文信息,从而提高不同地物之间的可分性。

(3) 最终的分类模块: 包括一个全局池化层 (Global average pooling, GAP)、一个全连接层 (Fully connected, FC) 和一个 Softmax 分类器。

此外,在多尺度扩张卷积模块之间利用多个不同卷积核数量的 3 \times 3 卷积层 (Conv) 进行连接。

城中村遥感识别网络的具体参数配置如表 1 所示,具体给出了分类网络每一个模块对应的输入尺寸、输出尺寸、卷积核尺寸、滤波器数量、步长等。同时,该网络用步长为 2 的卷积层代替了最大池化层,

表 1 MD-CNN 参数配置
Tab. 1 MD-CNN configuration

名称	输入尺寸	输出尺寸	卷积核尺寸	滤波器数量	步长
输入层	$224 \times 224 \times 3$				
Conv 1	$224 \times 224 \times 3$	$112 \times 112 \times 64$	3×3	64	2
Conv 2	$112 \times 112 \times 64$	$64 \times 64 \times 128$	3×3	128	2
Dilated block 1	$64 \times 64 \times 128$	$64 \times 64 \times 128$			
Dilated block 2	$64 \times 64 \times 128$	$64 \times 64 \times 128$			
Conv 3	$64 \times 64 \times 128$	$32 \times 32 \times 256$	3×3	256	2
Dilated block 3	$32 \times 32 \times 256$	$32 \times 32 \times 256$			
Dilated block 4	$32 \times 32 \times 256$	$32 \times 32 \times 256$			
Conv 4	$32 \times 32 \times 256$	$16 \times 16 \times 512$	3×3	512	2
Dilated block 5	$16 \times 16 \times 512$	$16 \times 16 \times 512$			
Dilated block 6	$16 \times 16 \times 512$	$16 \times 16 \times 512$			
非局部特征提取模块	$16 \times 16 \times 512$	$16 \times 16 \times 512$			
GAP	$16 \times 16 \times 512$	$1 \times 1 \times 512$		16×16	
FC	512	128			
Softmax	128	2			

从而在对特征图进行尺寸压缩的基础上进一步提高其特征提取能力。最终 Softmax 分类器的输出维度为 2 维, 分别对应城中村和非城中村共两个类别。

2.2 多尺度扩张卷积模块

城中村识别需要代表性和可分性强的特征, 才能有效提高分类效果。提出了一个多尺度扩张卷积模块, 用于提高模型对于城中村尺度变化的适应性。具体而言, 该模块由不同扩张率的卷积经过多尺度连接而形成, 从而有利于学习到多层次、多尺度的特征。该模块的具体结构如图 4 所示。图中 r 表示扩张率, W, H, C 分别表示宽、高、通道数。

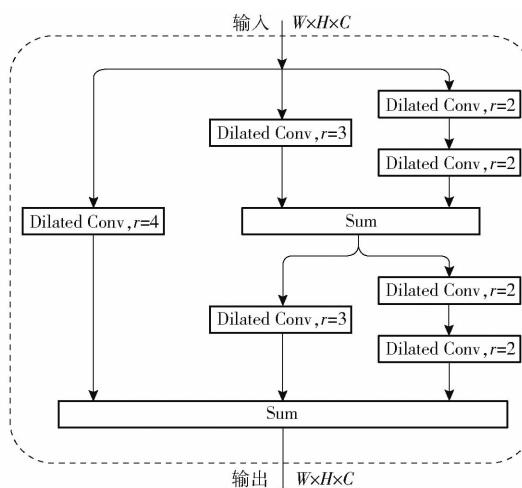


图 4 多尺度扩张卷积模块

Fig. 4 Structure of MD-CNN

从图 4 可以看出, 该模块包含了多个并行的分支, 不同分支的卷积具有不同的扩张率。采用相加(Sum)的方法用于多分支特征的聚合, 从而保证了输入和输出特征维数的一致性。这种设计可以对多尺度特征进行提取, 从而提高地物可分性。

不同扩张率对应的感受野大小遵循公式

$$k' = k + (k-1)(r-1) \quad (1)$$

$$S_{RF} = (2^{r+1}-1)(2^{r+1}-1) \quad (2)$$

式中 k, k' 分别为原始的卷积核尺寸和扩张之后的卷积核尺寸, S_{RF} 为扩张后的感受野大小。

从图 5 可以看出, 当扩张率是 2 时, 卷积核尺寸从 3 变为 5, 感受野大小从 3 变为 7。同时, 从图 5 也可以看出, 标准卷积可以视为扩张卷积在扩张率为 1 时的特例。

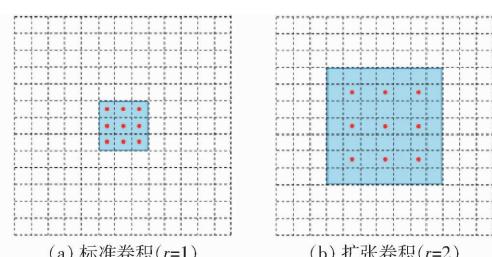


图 5 标准卷积和扩张卷积

Fig. 5 Standard convolution and dilated convolution

2.3 非局部特征提取模块

本文使用扩张卷积的目的之一是扩大卷积神经网络的感受野, 从而提高其捕捉长距离依赖关系的能力。然而, 扩张卷积本质上属于局部操作, 即它的输出只与局部的感受野有关。然而在遥感图像中, 局部操作并不能很好地提供图像的全局特征和上下文关系信息。为了解决这个问题, 探索了非局部特征提取模块在遥感图像全局特征提取和建模中的应用, 从而提高空间特征的代表性。该模块的结构如图 6 所示。

上述非局部特征提取模块借鉴于最新的非局部神经网络的研究^[24], 其性能已经在自然图像分类、

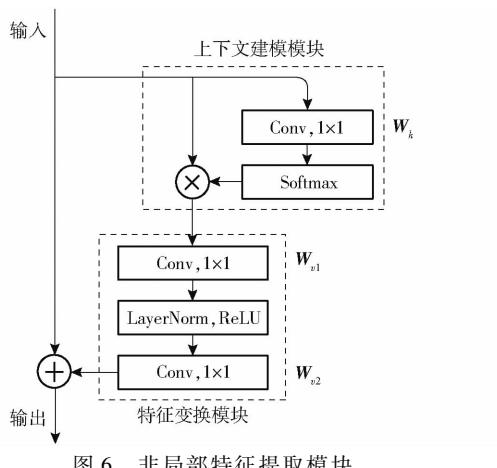


图 6 非局部特征提取模块

Fig. 6 Structure of non-local feature extraction module

目标检测、语义分割等领域得到了充分验证。具体而言,该非局部特征提取模块包含两部分,一是上下文建模模块(context modeling),二是特征变换模块(transform),其中 LayerNorm(LN) 层用于简化优化过程,使用更少的模型参数获得相似的模型性能。上下文建模模块主要用于捕捉图像中的长距离依赖关系,从而提供场景的上下文聚合信息;特征变换模块主要用于对提取的全局特征进行逐通道的注意力加权处理,从而进一步突出信息量较大的特征,并对噪声进行抑制。上述非局部特征提取模块的具体计算公式为

$$z_i = x_i + \mathbf{W}_{v2} \text{ReLU} \left(\text{LN} \left(\mathbf{W}_{v1} \sum_{j=1}^{N_p} \alpha_j x_j \right) \right) \quad (3)$$

$$\text{其中 } \alpha_j = \frac{\exp(\mathbf{W}_k x_j)}{\sum_m \exp(\mathbf{W}_k x_m)} \quad (4)$$

式中 z_i 为最终提取的全局特征, N_p 为图像的总像素数, x 为模块的输入。其中 x 的下角 i 代表当前输入的索引, j 为枚举所有可能输入的索引, m 用于对全局点计算求和, 以计算全局注意力, 其范围为 $1 \sim N_p$ 。 α_j 为上下文建模模块中对应的全局注意力权重, LN 为模块中 LayerNorm 层。 \mathbf{W}_k 表示上下文建模模块中的 1×1 卷积变换矩阵, \mathbf{W}_{v1} 、 \mathbf{W}_{v2} 表示特征变换模块中 LN 前、后的 1×1 卷积变换矩阵。

2.4 模型训练与精度评估

本文设计的城中村遥感识别模型属于深度学习模型, 其训练需要海量样本数据的支撑。在本研究中, 训练样本的数量有限, 因此容易造成分类模型的过拟合。为了缓解模型的过拟合问题, 本文采用数据增强的方法进行训练数据的扩充。具体而言, 对训练样本分别进行水平翻转和垂直翻转并旋转 90° 、 180° 、 270° 。经过上述数据增强操作, 训练样本的数量将扩充至原始数量的 6 倍。

在分类网络开始训练之前, 所有的参数需进行

初始化。在本文中, 选用文献[25]的方法进行参数初始化, 其优势是能够保证网络训练过程的稳定性, 并能够提高网络的收敛速度。

尽管进行了数据增强, 但是训练样本的数量仍然偏少, 因此分类模型仍存在过拟合的风险。为了进一步避免过拟合, 本文在所有标准卷积层后面使用了批归一化^[26](Batch normalization, BN), 同时对卷积参数使用 L2 正则化, 并在最后的 Softmax 分类层之前增加 dropout 层, 进一步提高网络的鲁棒性, 其中 dropout 的概率设置为 0.5。

在优化器的选择上, 选取了 Adam 算法^[27], 其初始学习率设置为 10^{-5} 。相比于随机梯度下降法(Stochastic gradient descent, SGD), Adam 算法的优点是在于模型优化的过程中可以自适应调节学习率, 不需要编写额外的学习率下降函数。同时, 使用了 early-stopping 策略^[28]进行最优模型的选取, 将训练集的 20% 划分为验证集, 使用验证集损失作为选取最优模型的度量。在获取当前的最优模型之后, 再进行 N 轮模型迭代, 如果验证集损失不下降, 则结束训练。在本文中, N 设置为 40。

损失函数选为交叉熵(Cross-entropy, CE)损失^[29], 计算方式为

$$L_{CE} = - \sum_i y_i^p \lg y_i \quad (5)$$

式中 y_i ——真实的标签数据

y_i^p ——模型预测结果

本文编程框架为 TensorFlow, 操作系统为 Ubuntu 16.04, CPU 为 Intel CORE i7-7800, GPU 为 NVIDIA GTX TitanX。

在完成模型训练之后, 使用测试集对模型进行精度验证。具体而言, 利用测试集进行混淆矩阵的计算, 同时, 总体分类精度(Overall accuracy, OA)和 Kappa 系数都可以从混淆矩阵中计算得到。其中 OA 表示分类正确的样本数占总样本数的比例, Kappa 系数代表了预测结果与真实结果之间的相似程度。

2.5 对比模型

为了进一步验证模型性能, 同时选取 VGG^[30]、ResNet^[25]、DenseNet^[31] 进行对比实验, 其中训练集和测试集的选取与本文模型保持一致。

具体而言, VGG 是在 AlexNet 的基础上, 采用连续多个 3×3 的卷积替换原始 AlexNet 中更大的卷积, 并利用多个最大池化层(Max pooling)连接卷积层对数据进行下采样, 在给定感受野的情况下提升网络深度, 从而一定程度上提升了网络性能。本文使用的对比模型为 VGG19, 其网络结构及参数如图 7 所示^[30]。

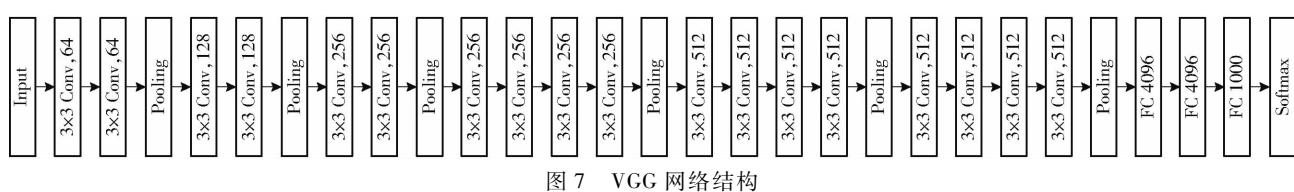


Fig. 7 Network structure of VGG

ResNet 设计了基于跳层连接的残差块(图 8^[25])，能够将深层网络通过恒等映射转化为浅层网络，一定程度上解决了深层网络所遇到的梯度消失、网络性能退化的问题。在本文中，使用 ResNet-50 作为对比模型。

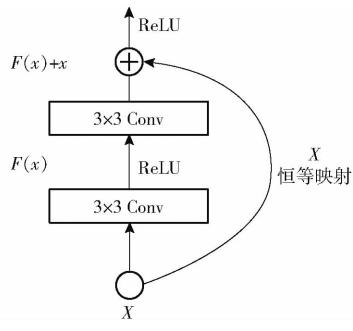


图 8 残差块结构

Fig. 8 Structure of residual block

DenseNet 在 ResNet 的基础上，对网络当前层与所有后续层之间进行稠密连接，能够实现更深层网络的训练。通过稠密连接中的特征融合层(concat)，DenseNet 还能实现特征维度上的特征再利用。图 9 为 5 层稠密连接块的 DenseNet 示例^[31]，本文使用 DenseNet-201 作为对比模型。

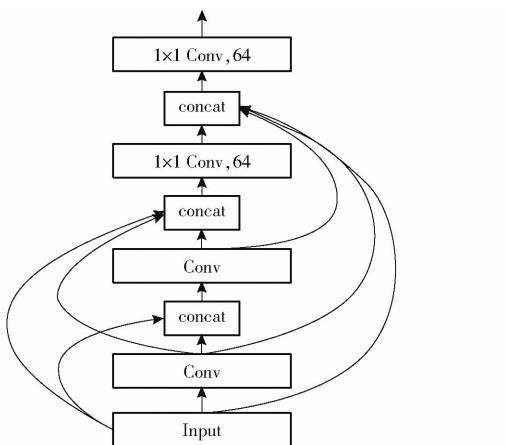


图 9 稠密块的网络结构

Fig. 9 Structure of dense block

3 结果与分析

3.1 城中村遥感识别结果

利用训练好的城中村遥感识别模型对北京二环到六环区域进行滑窗识别，具体结果如图 10 所示。可以看出，北京市二环到四环之间城中村主

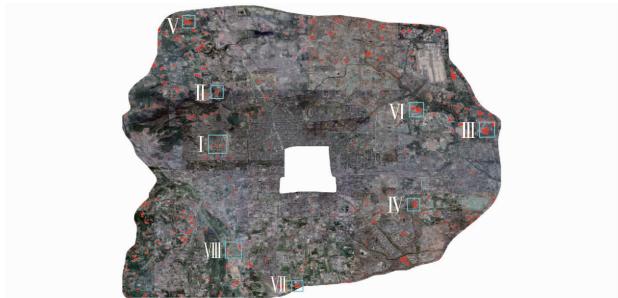


图 10 研究区城中村遥感识别结果

Fig. 10 Identification result of UVs in research

要以小区域零散分布为主，而四环到六环之间主要以大面积聚集和连片分布为主。究其原因，随着北京快速城市化，靠近市中心的村庄在城市化进程中逐渐被吸纳或自我形态发生改变，部分区域甚至按照规划融入到城市景观中，从而导致了区域内城中村呈零散分布的态势；而在城市近郊及更外围区域内，由于城市化进程较为缓慢，大部分仍保持原有村庄布局与分布形态，呈连片分布态势。

为进一步评估本文的城中村遥感识别结果，图 11 给出了 8 个典型区域的识别结果与对应的遥感图像，可以看出，识别结果与城中村吻合程度较高。同时，由于城中村周围景观格局复杂多变、建筑形式多样，具有较高的空间异质性，因此存在目视解译都极易发生混淆的区域。如图 12 所示，子区域 I 和子区域 II 在建筑密集程度、建筑材质及建筑群规模上均极为相似，利用腾讯地图获取各区域街景，发现子区域 II 街景表现出街道整洁、建筑无违规搭建等特点，为联排别墅，而子区域 I 街景体现出街道狭窄、建筑杂乱的特点。而本文模型可以对上述区域进行正确识别，进一步验证了本文模型的性能。

此外在研究区内还存在其他与城中村相似的区域(图 13)，也将影响城中村识别的精度，如建筑工地、工厂、别墅区等。

3.2 城中村遥感识别精度分析

在 3.1 节中，通过目视解译可以定性评价城中村识别模型的效果。为进一步定量评价本文模型的性能，基于测试集进行混淆矩阵计算，结果如表 2 所示。本文模型总体精度为 94.27%，Kappa 系数为 0.8839，取得了较好的识别效果。同时，由于本文

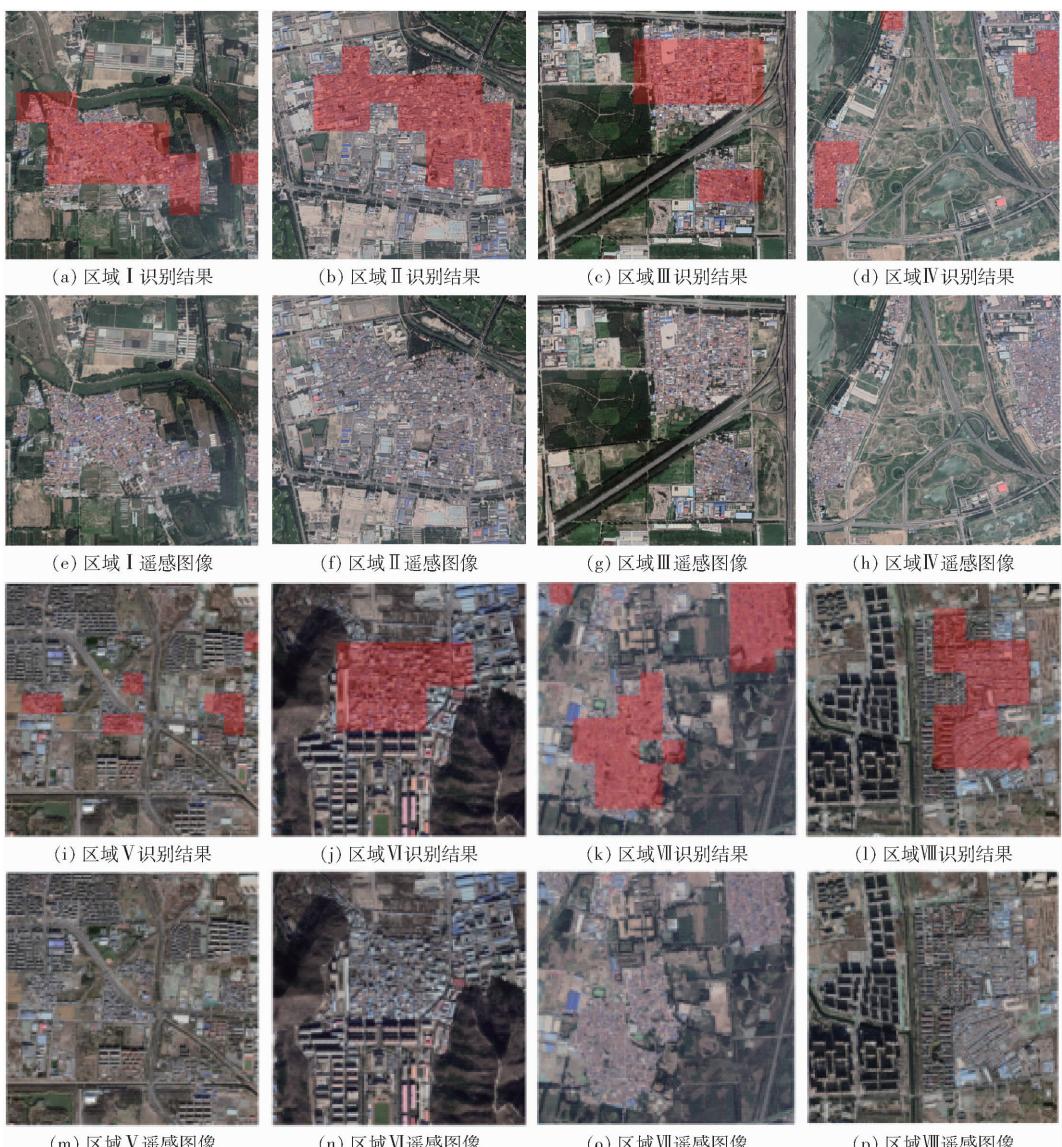


图 11 典型区域城中村图像及识别结果

Fig. 11 Typical area of UVs and identification result



图 12 易混淆区域识别结果

Fig. 12 Easily-confused identification results

将城中村识别视为遥感场景分类问题,在成图过程中基于 224 像素×224 像素的图像窗口对整幅图像进行预测,导致所提取的城中村边界较为粗糙,出现

锯齿现象。在未来研究中,拟采用 U-Net 等全卷积神经网络等模型,以获取更加精确的城中村边界范围。

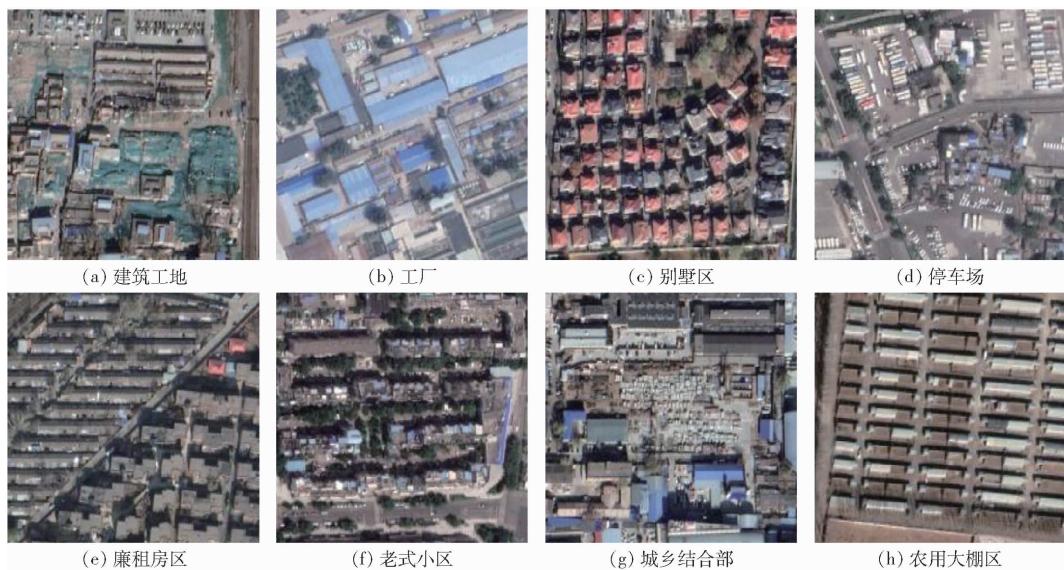


图 13 易混淆区域示例

Fig. 13 Easily-confused areas

表 2 混淆矩阵

Tab. 2 Confusion matrix

类别	地表真实测试数据		
	城中村	非城中村	用户精度/%
城中村	203	9	95.75
非城中村	13	159	92.44
生产精度/%	93.98	94.64	

表 2 混淆矩阵

表 3 模型精度比较

Tab. 3 Comparation of model precision

模型类别	总体精度/%	Kappa 系数
VGG	84.64	0.6860
ResNet	87.76	0.7576
DenseNet	91.15	0.8174
本文模型	94.27	0.8839

3.3 与其他深度学习模型对比

为了更进一步地验证本文提出模型的有效性,与计算机视觉领域常用模型(VGG、ResNet、DenseNet)进行实验对比,并采用相同的训练集和测试集。

精度对比结果如表 3 所示,与其他深度学习模型相比,本文提出的 MD-CNN 模型精度最高。具体而言,VGG 整体精度最低,为 84.64%,主要由于其网络结构较为简单,仅为多层卷积堆叠,模型训练容易陷入过拟合问题中,对于复杂场景的特征提取和表达能力有限。相比 VGG,ResNet 引入了跳层连接,有效缓解了梯度消失,通过加深网络层数以提高特征表达的有效性,总体精度可达 87.76%。DenseNet 则包含了更多的跳层连接,从而能够更好地聚合特征,效果最好,总体精度达到 91.15%。相比于上述模型,本文提出的 MD-CNN 通过多尺度扩张卷积可以更好地适应城中村形状、尺度上的变

异性,并能够提取图像的全局语义特征,从而取得了更高的分类精度。

4 结论

(1) 针对我国复杂城市景观格局下城中村的形狀、尺度等特点,基于多尺度扩张卷积神经网络提出了一种新的城中村遥感识别模型,在城中村遥感识别方面具有较好的效果。

(2) 以北京市为研究区开展实验并与其它典型卷积神经网络进行对比,结果表明,引入扩张卷积与非局部特征提取模块能够提高模型对于易出现形狀、尺度变异的城中村识别精度,且所提出的模型识别效果最佳,总体精度可达 94.27%,Kappa 系数为 0.8839。

(3) 本研究可以提供精确的城中村空间分布信息,为城乡统一规划、城市化进程监测等提供数据支撑。

参考文献

- [1] 林雄斌,马学广,李贵才. 快速城市化下城中村非正规性的形成机制与治理[J]. 经济地理, 2014, 34(6): 162–168.
LIN Xiongbin, MA Xueguang, LI Guicai. Formation and governance of informality in urban village under the rapid urbanization process[J]. Economic Geography, 2014, 34(6): 162–168. (in Chinese)
- [2] WEI C, MANLEY E. Detecting and analysing “urban villages” in the Pearl River delta using multi-source remote sensing data [C]//AGILE PhD School, 2015.

- [3] 兰宗敏, 冯健. 城中村流动人口日常活动时空间结构: 基于北京若干典型城中村的调查[J]. 地理科学, 2012, 32(4): 409–417.
LAN Zongmin, FENG Jian. The spatio-temporal structure of migrant's daily activities of village in city: case of typical villages in city of Beijing, China[J]. Scientia Geographica Sinica, 2012, 32(4): 409–417. (in Chinese)
- [4] 韩笋生, 埃里克·盖伊西耶, 杨跃龙. 加纳快速城镇化中的城市非正规居民点研究[J]. 国际城市规划, 2018, 33(5): 70–78.
HAN Sunsheng, ERIC Gaisie, YANG Yuelong. Research on urban informal settlements in a rapidly urbanizing Ghana[J]. Urban Planning International, 2018, 33(5): 70–78. (in Chinese)
- [5] 郭秋萍, 邹振东, 李宏永, 等. 深圳市城中村的热环境特征与热岛强度分析[J]. 生态环境学报, 2015, 24(3): 427–435.
GUO Qiuping, ZOU Zhendong, LI Yonghong, et al. Analysis on the thermal environment of urban village in Shenzhen[J]. Ecology and Environmental Sciences, 2015, 24(3): 427–435. (in Chinese)
- [6] ARIMAH B C. The face of urban poverty: explaining the prevalence of slums in developing countries[M]. Oxford: Oxford University Press, 2010.
- [7] ZHAO L, REN H, CHENG C, et al. A partition-based detection of urban villages using high-resolution remote sensing imagery in Guangzhou, China[J]. Remote Sensing, 2020, 12(14): 2334.
- [8] 王伟伟, 李润国, 赵青. 新型城镇化背景下城中村改造的问题与对策研究[J]. 宏观经济研究, 2015(8): 41–47.
- [9] OWEN K K, WONG D W. An approach to differentiate informal settlements using spectral, texture, geomorphology and road accessibility metrics[J]. Applied Geography, 2013, 38(4): 107–118.
- [10] 赵云涵, 陈刚强, 陈广亮, 等. 耦合多源大数据提取城中村建筑物: 以广州市天河区为例[J]. 地理与地理信息科学, 2018, 34(5): 7–13.
ZHAO Yunhan, CHEN Gangqiang, CHEN Guangliang, et al. Integrating multi-source big data to extract buildings of urban villages: a case study of Tianhe District, Guangzhou[J]. Geography and Geo-Information Science, 2018, 34(5): 7–13. (in Chinese)
- [11] 刘辉. 基于高分辨率遥感影像的城中村提取方法研究[D]. 武汉: 武汉大学, 2018.
LIU Hui. Study of urban village detection methods based on high-resolution remote sensing imagery[D]. Wuhan: Wuhan University, 2018. (in Chinese)
- [12] ANSARI R A, MALHOTRA R, BUDDHIRAJU K M. Identifying informal settlements using contourlet assisted deep learning [J]. Sensors, 2020, 20(9): 2733.
- [13] LIU J, FENG Q, WANG Y, et al. Urban green plastic cover mapping based on VHR remote sensing images and a deep semi-supervised learning framework[J]. ISPRS International Journal of Geo-Information, 2020, 9(9): 527.
- [14] WEI Y, WANG Z, XU M. Road structure refined CNN for road extraction in aerial image[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 709–713.
- [15] ZHOU W, MING D, LÜ X, et al. SO-CNN based urban functional zone fine division with VHR remote sensing image[J]. Remote Sensing of Environment, 2020, 236(44): 111458.
- [16] 朱德海, 刘逸铭, 冯权泷, 等. 基于 GEE 的山东省近 30 年农业大棚时空动态变化研究[J/OL]. 农业机械学报, 2020, 51(1): 168–175.
ZHU Dehai, LIU Yiming, FENG Quanlong, et al. Spatial-temporal dynamic changes of agricultural greenhouses in Shandong Province in recent 30 years based on Google Earth Engine[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 168–175. http://www.j-csam.org/jesam/ch/reader/view_abstract.aspx?flag=1&file_no=20200118&journal_id=jesam. DOI: 10.6041/j.issn.1000-1298.2020.01.018. (in Chinese)
- [17] 李旭青, 张秦雪, 安志远, 等. 基于可变形全卷积神经网络的冬小麦自动解译研究[J/OL]. 农业机械学报, 2020, 51(9): 144–151.
LI Xuqing, ZHANG Qinxue, AN Zhiyuan, et al. Automatic interpretation of winter wheat based on deformable full convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9): 144–151. http://www.j-csam.org/jesam/ch/reader/view_abstract.aspx?flag=1&file_no=20200917&journal_id=jesam. DOI: 10.6041/j.issn.1000-1298.2020.09.017. (in Chinese)
- [18] 汪传建, 赵庆展, 马永建, 等. 基于卷积神经网络的无人机遥感农作物分类[J/OL]. 农业机械学报, 2019, 50(11): 161–168.
WANG Chuanjian, ZHAO Qingzhan, MA Yongjian, et al. Crop identification of drone remote sensing based on convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(11): 161–168. http://www.j-csam.org/jesam/ch/reader/view_abstract.aspx?flag=1&file_no=20191118&journal_id=jesam. DOI: 10.6041/j.issn.1000-1298.2019.11.018. (in Chinese)
- [19] HOFMANN P. Detecting informal settlements from IKONOS image data using methods of object oriented image analysis—an example from Cape Town (South Africa) [C] // Proceedings of the 2nd International Symposium Remote Sensing of Urban Areas. Regensburg, 2001: 107–118.
- [20] MBOGA N, PERSELLO C, BERGADO J, et al. Detection of informal settlements from VHR images using convolutional neural networks[J]. Remote Sensing, 2017, 9(11): 1106.
- [21] WURM M, STARK T, ZHU X X, et al. Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 150(3): 59–69.
- [22] LI Y, HUANG X, LIU H. Unsupervised deep feature learning for urban village detection from high-resolution remote sensing images[J]. Photogrammetric Engineering & Remote Sensing, 2017, 83(8): 567–579.

- on unmanned surface vehicle [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9): 175–185, 174. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200920&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2020.09.020. (in Chinese)
- [19] 曹守启, 葛照瑞, 张铮. 基于改进粒子群优化算法的溶解氧调控系统设计[J]. 传感器与微系统, 2020, 39(6): 113–115. CAO Shouqi, GE Zhaorui, ZHANG Zheng. Design of dissolved oxygen control system based on improved particle swarm optimization algorithm [J]. Sensors and Microsystems, 2020, 39(6): 113–115. (in Chinese)
- [20] 袁森, 贺松. 基于 CentOS 6.5 的服务器搭建与配置[J]. 微型机与应用, 2014, 33(16): 40–41, 44. YUAN Sen, HE Song. Server construction and configuration based on CentOS 6.5 [J]. Microcomputer and Application, 2014, 33(16): 40–41, 44. (in Chinese)
- [21] 代超, 邓中亮. 基于 Netty 的面向移动终端的推送服务设计[J]. 软件, 2015, 36(12): 1–4, 21. DAI Chao, DENG Zhongliang. Design of push service for mobile terminal based on Netty [J]. Software, 2015, 36(12): 1–4, 21. (in Chinese)
- [22] 欧勤坪, 余建桥. 基于 SpringMVC + iBATIS 框架的生物信息数据库的设计与实现[J]. 西南大学学报(自然科学版), 2008, 30(11): 142–145. OU Qinping, YU Jianqiao. Design and implementation of biological information database based on SpringMVC + iBATIS framework [J]. Journal of Southwest University (Natural Science Edition), 2008, 30(11): 142–145. (in Chinese)
- [23] 吴鸿雁. 网站页面设计中的人机界面设计分析[J]. 计算机工程与设计, 2008(21): 5633–5634, 5637. WU Hongyan. Analysis of man-machine interface design in website page design [J]. Computer Engineering and Design, 2008(21): 5633–5634, 5637. (in Chinese)
- [24] BORYCZKO J, BLACHNIK M, GOLAK S. Optimization of warehouse operations with genetic algorithms [J]. Applied Sciences, 2020, 10(14): 4817.
- [25] ZHANG Juanzhi, XIONG Fuli, DUAN Zhongxing. Research on resource scheduling of cloud computing based on improved genetic algorithm [J]. Journal of Electronic Research and Application, 2020, 4(2): 4–9.
- [26] 王锦, 赵德群. 基于遗传算法的神经网络权值优化方法[J]. 电子元器件与信息技术, 2018(9): 33–36. WANG Jin, ZHAO Dequn. Neural network weight optimization method based on genetic algorithm [J]. Electronic Components and Information Technology, 2018(9): 33–36. (in Chinese)
- [27] 缪新颖, 葛廷友, 高辉, 等. 基于神经网络和遗传算法的池塘溶解氧预测模型[J]. 大连海洋大学学报, 2011, 26(3): 264–267. MIAO Xinying, GE Tingyou, GAO Hui, et al. Prediction model of dissolved oxygen in ponds based on neural network and genetic algorithm [J]. Journal of Dalian Ocean University, 2011, 26(3): 264–267. (in Chinese)
- [28] 张青, 王学雷, 张婷, 等. 基于 BP 神经网络的洪湖水质指标预测研究[J]. 湿地科学, 2016, 14(2): 212–218. ZHANG Qing, WANG Xuelei, ZHANG Ting, et al. Study on water quality index prediction of Honghu Lake based on BP neural network [J]. Wetland Science, 2016, 14(2): 212–218. (in Chinese)

(上接第 189 页)

- [23] 崔成, 任红艳, 赵璐, 等. 基于街景影像多特征融合的广州市越秀区街道空间品质评估[J]. 地球信息科学学报, 2020, 22(6): 1330–1338. CUI Cheng, REN Hongyan, ZHAO Lu, et al. Street space quality evaluation in Yuexiu District of Guangzhou City based on multi-feature fusion of street view imagery [J]. Journal of Geo-Information Science, 2020, 22(6): 1330–1338. (in Chinese)
- [24] CAO Y, XU J, STEPHEN L, et al. Gcnet: non-local networks meet squeeze-excitation networks and beyond [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops (ICCVW), 2019: 1971–1980.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [26] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [J]. arXiv preprint arXiv:1502.03167, 2015.
- [27] KINGMA D P, BA J. Adam: a method for stochastic optimization [J]. arXiv preprint arXiv:1412.6980, 2014.
- [28] PRECHELT L. Early stopping—but when? [M] // MONTAVON G, ORR G B, MÜLLER K. Neural networks: tricks of the trade: second edition. Berlin, Heidelberg: Springer, 2012: 53–67.
- [29] COX R T. Probability, frequency and reasonable expectation [J]. American Journal of Physics, 1946, 14(1): 1–13.
- [30] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv preprint arXiv: 1409.1556, 2014.
- [31] HUANG G, LIU Z, VAN DRT MAATEN L, et al. Densely connected convolutional networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700–4708.