引文格式：郭英琦,张翔,李若兰,等. 顾及地理尺度的矢量建筑物变化检测方法[J]. 地理空间信息, 2024, 22(7): 44-49. doi:10. 3969/j.issn. 1672-4623.2024.07.010

顾及地理尺度的矢量建筑物变化检测方法

郭英琦[1]，张　翔[2*]，李若兰[1]，程　雄[1]
（1. 武汉大学 资源与环境科学学院，湖北 武汉 430079；2. 中山大学 测绘科学与技术学院，广东 珠海 519082）

摘　要：高现势性数据与现有矢量地理实体数据库融合和更新时，由于现有基础地理数据库具有特定规范、精度与比例尺要求，使变化检测异常困难。鉴于此，提出了一种顾及地理尺度的变化检测样本构建方法。首先通过数据匹配建立新旧矢量数据同名实体间的对应关系，再通过固定尺度地理单元和数学形态学方法将变化样本聚焦在局部显著变化区域，以提高卷积神经网络对变化信息的尺度感知力。通过实验确定了样本地理单元的合适尺度，并对比了 AlexNet、GoogleNet 与传统 C4.5 决策树模型的变化检测效果。结果表明，基于图像的深度学习方法优于基于矢量人工特征的 C4.5 模型；基于固定尺度单元样本库的变化检测模型明显优于基于外接矩形样本的构建方法，进一步验证了该方法的有效性。

关键词：志愿者地理信息；变化检测；样本构建；OSM；卷积神经网络
中图分类号：P208　　**文献标志码：**B　　**文章编号：**1672-4623（2024）07-0044-06

Vector Building Change Detection Method Considering Geographical Scale

GUO Yingqi[1], ZHANG Xiang[2], LI Ruolan[1], CHENG Xiong[1]
(1. School of Resource and Environmental Science, Wuhan University, Wuhan 430079, China;
2. School of Geospatial Engineering and Science, Sun Yat-sen University, Zhuhai 519082, China)

Abstract: In order to solve the problem that the specific requirements of fusion and update of current data and existing vector geographical entity databases make it difficult to detect changes, we proposed a change detection sample construction method considering geographical scale. Firstly, we established the corresponding relationship between data entities with the same name by data matching. Then, we used the fixed-scale geographical unit and mathematical morphology method to focus change samples on the local change. Finally, we determined the appropriate scale of sample geographical unit by experiments, and compared the detection effects of AlexNet, GoogleNet and traditional C4.5 decision tree model. The results show that the deep learning method based on images is better than the C4.5 model based on vector artificial features. The change detection model based on the fixed-scale unit sample library is obviously better than the construction method based on the circumscribed rectangular sample.

Key words: volunteered geographical information, change detection, sample construction, OSM, convolutional neural network

现势性是测绘地理信息在地图导航、位置服务、城市规划等相关产业应用的基石，直接影响其价值与可持续发展。然而，由于需要实现多个尺度数据的同步更新，GIS 数据更新问题一直属于地理信息加工流程中的瓶颈之一[1]。德国、荷兰等测绘强国在采用数字化地图综合后，多尺度地形图数据库更新周期约为两年[2]。随着新型测绘遥感、众源地理信息、社会感知等技术手段的不断完善，特定信息要素层的更新周期明显缩短，如采用众包方式后，英国军测的 POI、地址等信息最快每周可更新一次，但建筑、道路等基础设施数据更新周期依然长达 6 个月[3]，这还不包含对多尺度空间数据的级联更新时间[4]。因此，有必要进一步探索智能高效的变化检测与更新策略。本文聚焦于城市更新频发的建筑要素[5]，采用志愿者地理信息（VGI）作为更新信息源。VGI 数据与高分辨率遥感影像都具有较高的现势性，不同的是，VGI 数据是事件驱动的，具有更丰富的语义（建筑类型、功能、人文信息等），且不受天气等因素影响，可作为遥感手段的一种重要补充[6-7]。以 OpenStreetMap（OSM）为例，经过近 20 年的志愿者贡献，其已成为全球覆盖、语义丰富、实时更新的一种新型基础地理信息源[8-9]，尽管数据质量还存在分布不均等现象，但已在欧美等国家用于信息补全、变化检测、数据更新等任务，以提高基础测绘效率[10-11]。

收稿日期：2022-10-07。
项目来源：国家自然科学基金面上基金资助项目（41671384）。
第一作者简介：郭英琦（1998—），硕士研究生，主要从事地图制图综合等方面的工作，E-mail：q894495183@163.com。
通信作者：张翔（1982—），教授，博士生导师，主要研究方向为地理信息智能处理，E-mail：zhangx795@mail.sysu.edu.cn。

目前基于矢量数据的变化检测主要根据专家知识提取特征（位置、大小、方向、形状和语义等相似性），通过建立专家规则或采用监督学习的方法进行建筑物变化检测[12-14]，如Bouziani M[13]等提取了GIS矢量数据中的植被、道路、水系、建筑上下文等特征，建立规则库并与遥感影像结合进行建筑物变化检测，Zhou X[14]等利用建筑物面积、相交区域比率、形状相似度等特征，基于建筑物之间的对应关系建立专家知识决策树进行建筑物变化检测；但手动特征工程有较大的局限性，如隐性知识难以形式化等问题。近年来，鉴于其在自动提取特征、处理数据非线性关系、数据分层抽象等方面的优势，深度学习在GIS矢量数据语义增强和模式识别中的应用逐渐增多[15-16]；但由于缺乏适合的数据表达，目前几乎没有直接针对矢量数据进行变化检测的深度学习方法。因此，本文将矢量变化检测问题转化为基于图像的视觉认知问题，拟采用深度卷积神经网络（DCNN）开展研究，这与人眼判别矢量数据变化本质上是一致的。DCNN能够很好地学习图像中隐藏的多层次视觉特征，且图像具有规范的阵列结构，因此在图像识别上具有较强的泛化能力，并逐渐应用于高分遥感影像的变化检测中[17-19]，如Liu T[20]等提出了一种基于对象分析框架的CNN变化检测方法；季顺平[21]等提出了一种用于分类的全空洞卷积神经元网络，对城市土地覆盖进行了像素级和对象级的变化检测。

然而，基于遥感影像的变化检测主要是识别不同时期影像的“视觉差异”[20-22]，本文的不同则是在矢量数据差异中甄别真正的实体变化。图1中蓝+绿表示被更新建筑，蓝+红表示更新OSM建筑，蓝色表示二者的公共部分，可以看出，图1a、1c中更新源和被更新矢量数据存在细节层次差异和非系统性位移，除图1b中的M情形和图1d中的纯粉色，其他的大多数数据差异（N情形）并不是有意义的变化。引起这些矢量数据差异的原因包括：①数据采集精度和尺度带来的误差和细节层次差异；②地图综合引起的非系统性位移（无法用线性变换纠正）；③数据规范引起的几何形态差异（如地形图采集建筑物屋顶轮廓，而地籍数据则采集包括庭院、门廊在内的轮廓）；④地理实体的物理（新建、拆除、局部重建）与语义变化。从图1的“视觉差异”中提取真实变化的核心是一个视觉理解问题，本文以OSM数据为潜在变化源，将矢量数据变化检测转换为一个图像识别变化分类问题。深度学习模型极大依赖高质量样本数据集，GIS矢量数据生成的图像类似于草图或绘画，与自然图像样本库（ImageNet、CIFAR）具有不同的分布。同时，不同于目标识别和分类，变化检测问题难以通过对这些通用样本库的迁移学习来实现，因此建立领域特定的矢量数据变化样本库尤为重要。此外，相较于图像识别中的目标尺寸（大猫小猫都是猫），地理尺度（建筑物大小）在变化检测上具有更重要的作用[14]。为处理矢量数据变化检测存在的这些问题，本文提出了一种顾及地理尺度的变化样本构建策略，并与常规样本构建方式进行对比，通过两种经典CNN验证构建策略。



图1　不同时期影像“视觉差异”识别结果

1　矢量建筑物变化检测的CNN方法

本文提出了一种矢量建筑物变化检测的图像样本库建立与训练方法，总体流程为：①将新旧矢量数据叠加，利用相似性进行同名实体匹配，生成对应关系（分为1∶1和m∶n关系）；②利用专家目视判别为新旧建筑数据匹配对进行变化状态标注；③以新旧数据匹配对为单元进行矢栅转换、视觉编码，建立图像样本库；④训练变化检测CNN，并对其进行评价。

1.1　面向建筑物变化检测的样本构建

训练使用的图像质量会显著影响DCNN模型的性能，样本图像的数据特征不明显、数据量过少、分辨率较低或正负样本数量差异大等都会导致变化信息难以提取[23]。因此，将建筑物的矢量数据转换为栅格图像构建建筑物变化样本库时，将面临待更新数据与OSM的新旧数据匹配以及矢量数据生成图像过程的地理尺度两个问题。

1.1.1　新旧建筑物数据匹配

待更新数据是经过少量制图综合（化简、合并、位移）处理的1∶10 000地形图建筑数据；而OSM数据信息来源广泛（遥感影像数字化、实地测量、第三方导入等），没有统一的标准规范，多数未经过制图综合，因此OSM数据具有更多的细节信息，这也是导致变化检测不确定的主要原因。如果要进行建筑物变化检测，首先需要解决异构数据源的匹配问题。由于两种数据在比例尺上差别不大，本文参考郭黎[24]等的研究，采用基于面积相似度的面状矢量数据匹配方法。首先将不同来源的矢量数据编码并作叠加处理，

计算重叠区域；再采用不同颜色表示不同来源的数据与重叠区域，建立两种数据源建筑物之间的6种定性关系（图2），m、n分别表示待更新数据建筑物数量和OSM数据建筑数量。根据上述的对应关系，可将矢量数据叠加并人工判别为变化和未变化建筑物两类，从而为生成的栅格图像数据集提供标签。

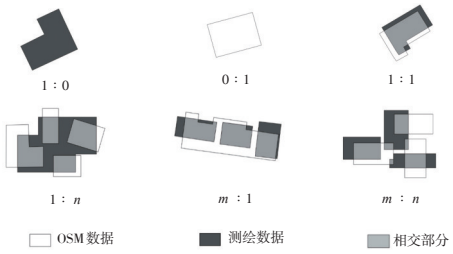


图2 不同数据源对应关系

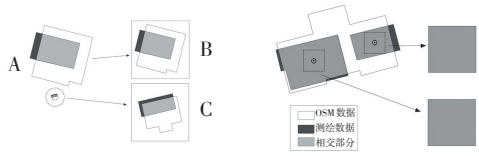
1.1.2 两种变化样本的生成

1）外接矩形方法。为提升深度学习模型的鲁棒性，在制作深度学习图像样本库时，通常需将判别目标的主体尽可能地填充整个图像，使模型能够学习到更多的细节[25-27]。对于矢量数据的变化检测，将矢量建筑数据转换为栅格图像最直观的方法是基于新旧建筑物轮廓并集的外接矩形范围生成截图（图3中B、C所示），简单易获取。然而，同样5%的面积变化，在小建筑上很可能不是变化，在大型建筑上就是局部扩建。利用外接矩形方法生成新旧建筑物的图像样本忽略了差异的绝对尺寸，导致DCNN难以学到有用信息，影响模型的训练结果。

2）固定尺度地理单元方法。为了保留形状差异的尺度信息，采用固定尺度地理单元方法生成图像样本。选择生成图像中心点时，若以新旧建筑物公共区域中心点生成样本图像，极端情况下图片内部将填充同一颜色（图3b），导致生成后的图像丢失有效信息，因此应将采样窗口聚焦在发生变化的局部区域。具体而言，本文采用数学形态学的收缩、膨胀算子，提取“显著”的数据差异部分。首先采用反向缓冲区运算将新旧数据的差异部分（图4a）向内偏移收缩特定距离（d = 15 m，1 ∶ 10 000地形图上化简、合并、位移所产生的差异量级），消除数据差异中由于数据采集精度、地图综合等产生的无关变化的次要差异（图4b）；然后向外偏移相同距离复位，得到“显著”的数据差异部分（图4c）；最后根据每个“显著”差异局部的中心点，按照采样窗口对矢量数据进行栅格化。

1.2 基于DCNN的变化检测模型训练与预测

本文采用AlexNet和GoogleNet两种经典模型进行变化检测训练。AlexNet网络包括5个卷积层、3个全



a 外接矩形法 b 固定尺度地理单元

图3 两种方法生成变化样本比较

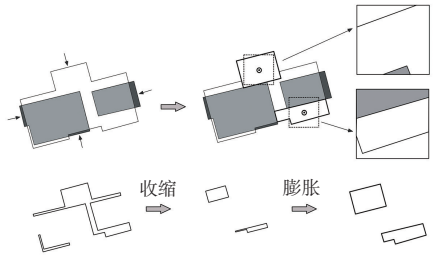


图4 数学形态学方法提取显著数据差异

连接层[28]；GoogleNet引入了Inception模块，使得网络能够在深度和宽度大幅增加的同时减少参数量，避免过拟合[29]。具体流程为：①划分训练集与测试集；②由于原始样本数据有限，采用旋转和镜像方法对训练数据集样本进行扩容；③由于样本库中负样本（不变）数量远多于正样本（变化），本文采用加权随机采样的方法[30]来平衡输入到模型中正负样本的比例；④模型评价与调参。

2 实验与结果分析

2.1 矢量数据、图像样本与模型参数

本文以荷兰地区45 km²内4 832栋建筑物的待更新数据为实验基础，比例尺为1 ∶ 10 000，获取对应区域的OSM建筑数据后，人工判别发生变化的建筑物为1 365栋，其中新建建筑731栋，拆除建筑205栋（图5）。首先根据矢量数据的索引号，采用深度优先搜索算法确定每张样本生成时包含的建筑物；然后利用ArcEngine进行二次开发，通过其绘制功能将矢量数据绘制成分辨率为500像素×500像素的RGB图像，从而生成原型系统；最后利用原型系统按固定尺度地理单元法生成包含5 471张图像的样本库，并采用外接矩形法生成了4 832张图像样本。

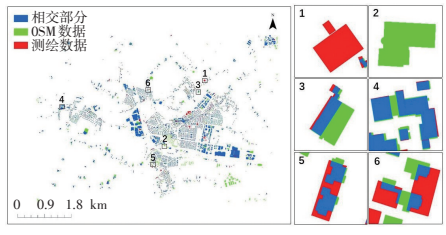


图5 实验区域

抽取样本库20%的数据用于测试模型训练效果与

精度评价，将剩余的图像按照4∶1的比例划分训练数据集和验证数据集，用于模型的训练调试。实验采用AlexNet和GoogleNet分别对两个样本库进行训练，基于PyTorch框架实现；硬件采用Intel Xeon CPU，显卡为两张NVIDIA TITAN xp；设置AlexNet模型的学习率为1×10^{-3}，GoogleNet模型的学习率为1×10^{-5}，优化器为SGD，动量为0.9；采用DropOut层（p=0.5）防止过拟合，每个模型迭代100次训练。实验采用正确率、精度、召回率和F1-Score等定量评价指标综合分析模型性能。

2.2　样本生成的地理单元尺度

固定尺度地理单元法生成样本时，首先需选取合适的范围，若生成的范围过大，将导致建筑物样本数据细节不够清晰，影响训练效果；若范围过小，则生成的数据集中会出现大量图片内部填充同一颜色的情况，降低数据集质量，因此选取合适的范围对于生成高质量的建筑物样本非常重要。基于此，实验选择10 m×10 m、20 m×20 m、30 m×30 m和40 m×40 m等4个地理单元尺度，并生成4个样本库，样本库中不包含新增或消失的建筑，同一建筑物在不同地理单元尺度下生成的样本见图6。本文采用GoogleNet训练不同尺度模型并进行测试，得到的结果见表1，可以看出，使用30 m×30 m尺度样本库训练的模型在正确率、精度和F1-Score指标上表现最佳；10 m×10 m尺度样本库训练的模型虽然对不变类别的召回率最高，但其对变化类别的召回率仅为11%，这是由于地理范围较小导致产生大量纯色图片，使得模型更倾向于将这些图片分类为不变。因此，本文选取30 m×30 m作为样本库生成图片的地理单元尺度，生成的部分样本见图7。

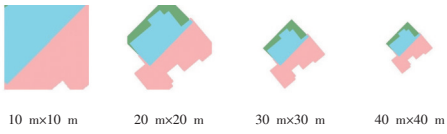


图6　不同地理单元尺度的生成样本

表1　GoogleNet在不同地理单元尺度下的训练结果

实际地理尺度/m	正确率/%	类别	精度/%	召回率/%	F1-Score
10×10	89.4	不变	90.1	99.0	94.3
		变化	56.3	11.0	17.8
20×20	89.5	不变	94.4	93.8	94.1
		变化	51.7	54.1	52.9
30×30	90.8	不变	95.9	93.6	94.7
		变化	60.5	70.9	65.3
40×40	90.4	不变	94.4	94.8	94.6
		变化	56.1	54.1	55.1

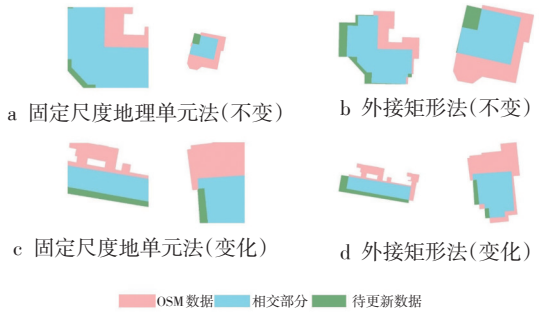


图7　固定尺度地理单元法与外接矩形法生成的部分样本

2.3　模型实验结果与比较分析

实验采用AlexNet与GoogleNet对图像样本库进行训练，并与C4.5决策树分类器的机器学习方法进行比较，C4.5决策树分类器以建筑物面积、面积比、数据源重叠部分面积占比和形状相似度为特征[31-32]，结果见表2，可以看出，DCNN模型在正确率、召回率、F1-Score上均优于C4.5模型，说明采用图像与深度学习的方式优于人工选取特征；GoogleNet的总体正确率在两种方法上均高于AlexNet，这与其在通用图像分类上的表现一致。以正确率最高的GoogleNet为例，固定尺度地理单元法的正确率为92.4 %，高于外接矩形方法。在不变样本的分类上，固定尺度地理单元法比外接矩形方法的精度和召回率更高，F1-Score也高出1.8，但二者的指标差异并不大，因为大多数类别为不变的建筑物面积较小，使用两种方法均能生成包含建筑物主体的样本（图7a、7b）。在判断变化样本时，外接矩形方法训练的模型召回率更高，但精度只有76.9 %，表明该方法训练的模型更易受地理尺度的影响。固定尺度地理单元法生成样本库训练的模型在综合评价指标F1-Score上表现更优，对不变和变化的样本判别上均优于外接矩形法，说明其能有效提升模型效果，使用AlexNet训练的模型得到的指标也呈现出相同的规律。

表2　总体结果比较

模型	生成方法	总体正确率/%	类别	精度/%	召回率/%	F1-Score
AlexNet	固定尺度地理单元法	91.1	不变	96.2	91.5	93.8
			变化	79.8	90.2	84.7
	外接矩形法	89.6	不变	97.3	88.0	92.4
			变化	75.4	93.8	83.6
GoogleNet	固定尺度地理单元法	92.4	不变	95.9	93.6	94.7
			变化	83.9	89.2	86.5
	外接矩形法	90.2	不变	97.0	89.0	92.9
			变化	76.9	93.0	84.2
C4.5	人工特征工程	85.5	不变	94.2	87.9	91.0
			变化	55.9	74.0	63.7

为更加直观地比较两种方法的表现，本文选取了

118 张人工较难判断的图片作为挑战集，利用训练后的 GoogleNet 进行预测。结果表明，固定尺度地理单元法的正确率为 85.6 %，而外接矩形法仅为 68.6 %；固定尺度地理单元法在不变和变化类别的 F1-Score 分别为 91.4 和 56.4，而外接矩形法分别为 80.2 和 24.5；固定尺度地理单元法训练的模型在指标上均优于外接矩形法训练的模型，表明本文提出的顾及地理尺度的样本生成方法在提高变化检测模型精度上的效果更好。

2.4 变化检测模型的可解释性

利用 Grad-CAM[33]方法对模型进行解释（图 8），热力图越偏向红色表示区域在模型训练中的贡献越大，可以看出，在判别不变样本时，两个模型都主要依赖于相交区域进行判断；而在判断变化样本时，固定尺度地理单元法训练的模型主要依赖于新增区域，这与人工判断的依据更为符合，外接矩形法的模型则标准不一，这也说明采用固定尺度地理单元法生成的样本库能为 DCNN 模型训练提供更多的判断依据，进而提升模型的预测结果，与前文的分析吻合。

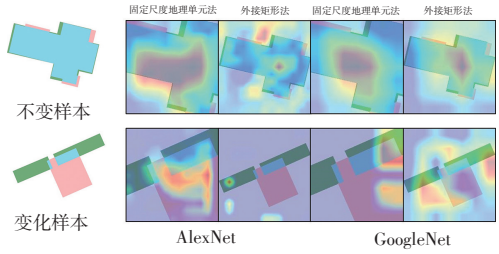


图 8 采用 Grad-CAM 方法解释模型对建筑样本的预测

3 结 语

本文针对建筑物要素的变化检测问题，将传统的矢量变化检测转化为图像识别问题，提出了一种顾及地理尺度的变化检测样本构建方法。利用该方法在面积为 45 km^2、建筑数量为 4 832 栋的区域进行实验，利用 CNN 模型进行训练，并与外接矩形法和人工特征的 C4.5 模型进行比较。结果表明，基于图像的深度学习方法优于传统的基于矢量人工特征的 C4.5 模型；采用固定尺度地理单元法训练的模型优于外接矩形法，证明了本文方法在变化检测上的有效性。两种 CNN 模型对不变类型的判别效果优于变化类型，因此下一步工作是增加变化类型的样本数量，进一步提升变化类型的判别效果，同时测试利用本文方法生成的样本库在更多深度学习模型上的表现效果。

参考文献

[1] 赵仁亮，陈军，王东华，等. 数字环境下的数据缩编更新方法[J]. 地理信息世界，2008，15(3):17-20

[2] Stoter J，van Smaalen J，Bakker N，et al. Specifying Map Requirements for Automated Generalization of Topographic Data[J]. The Cartographic Journal，2009，46(3):214-227

[3] Ordnance Survey Products[EB/OL]. (2022-03-14)[2022-05-12]. https://www. ordnancesurvey. co. uk/business-government/products/

[4] Zhang X，Yin W，Yang M，et al. Updating Authoritative Spatial Data from Timely Sources: A Multiple Representation Approach[J]. International Journal of Applied Earth Observation and Geoinformation，2018，72:42-56

[5] 王慧贤. 一种顾及多特征的建筑物变化检测方法[J]. 测绘地理信息，2020，45(6):91-96

[6] Goodchild M F. Citizens as Sensors: The World of Volunteered Geography[J]. GeoJournal，2007，69(4):211-221

[7] 丁建勋，刘亚楠，张新长，等. OpenStreetMap 数据下的空间数据更新方法[J]. 测绘通报，2016(6):94-97

[8] Heipke C. Crowdsourcing Geospatial Data[J]. ISPRS Journal of Photogrammetry and Remote Sensing，2010，65(6):550-557

[9] Dorn H，Törnros T，Zipf A. Quality Evaluation of VGI Using Authoritative Data: A Comparison with Land Use Data in Southern Germany[J]. ISPRS International Journal of Geo-information，2015，4(3):1 657-1 671

[10] Mooney P，Crompvoets J，Lemmens R. Crowdsourcing in National Mapping[J]. European Spatial Data Research Network Official Publication，2018，66:1-26

[11] Olteanu-raimond A M，Hart G，Foody G M，et al. The Scale of VGI in Map Production: A Perspective on European National Mapping Agencies[J]. Transactions in GIS，2017，21(1):74-90

[12] Matikainen L，Hyyppä J，Ahokas E，et al. Automatic Detection of Buildings and Changes in Buildings for Updating of Maps[J]. Remote Sensing，2010，2(5):1 217-1 248

[13] Bouziani M，Goïta K，He D C. Automatic Change Detection of Buildings in Urban Environment from very High Spatial Resolution Images Using Existing Geodatabase and Prior Knowledge[J]. ISPRS Journal of Photogrammetry and Remote Sensing，2010，65(1):143-153

[14] Zhou X，Chen Z，Zhang X，et al. Change Detection for Building Footprints with Different Levels of Detail Using Combined Shape and Pattern Analysis[J]. ISPRS International Journal of Geo-information，2018，7(10):406-429

[15] Yan X，Ai T，Yang M，et al. A Graph Convolutional Neural Network for Classification of Building Patterns Using Spatial Vector Data[J]. ISPRS Journal of Photogrammetry and

Remote Sensing,2019,150:259-273

[16] 王米琪,艾廷华,晏雄锋,等. 图卷积网络模型识别道路正交网格模式[J]. 武汉大学学报(信息科学版),2020,45(12):1 960-1 969

[17] Chu Y,Cao G,Hayat H. Change Detection of Remote Sensing Image Based on Deep Neural Networks[C]. 2016 2nd International Conference on Artificial Intelligence and Industrial Engineering (AIIE 2016),Atlantis Press,2016:262-267

[18] Lebedev M A,Vizilter Y V,Vygolov O V,et al. Change Detection in Remote Sensing Images Using Conditional Adversarial Networks[J]. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences,2018,42(2):565-571

[19] 刘恒恒,张春森,葛英伟,等. 多尺度特征融合深度学习建筑物的提取方法[J]. 地理空间信息,2022,20(2):97-100

[20] Liu T, Yang L, Lunga D. Change Detection Using Deep Learning Approach with Object-based Image Analysis[J]. Remote Sensing of Environment,2021,256:1-16

[21] 季顺平,田思琦,张驰. 利用全空洞卷积神经元网络进行城市土地覆盖分类与变化检测[J]. 武汉大学学报(信息科学版),2020,45(2):233-241

[22] Varghese A, Gubbi J, Ramaswamy A, et al. ChangeNet: A Deep Learning Architecture for Visual Change Detection[C]//Proceedings of the European Conference on Computer Vision Workshops,2018

[23] 王敏,陈金勇,王港,等. 面向深度学习的遥感图像目标样本生成方法[J]. 国外电子测量技术,2019,38(4):60-65

[24] 郭黎,郑海鹰,王豪. 面状矢量空间数据匹配技术研究[J]. 海洋测绘,2009,29(3):12-15

[25] 李卫. 深度学习在图像识别中的研究及应用[D]. 武汉:武汉理工大学,2014

[26] 高常鑫,桑农. 基于深度学习的高分辨率遥感影像目标检测[J]. 测绘通报,2014(增刊1):108-111

[27] 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):1 229-1 251

[28] Krizhevsky A, Sutskever I, Hinton G E. Imagenet Classification with Deep Convolutional Neural Networks[J]. Communications of the ACM,2017,60(6):84-90

[29] Szegedy C,Liu W,Jia Y,et al. Going Deeper with Convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2015:1-9

[30] Efraimidis P S, Spirakis P G. Weighted Random Sampling with a Reservoir[J]. Information Processing Letters, 2006(5):181-185

[31] Zhang X,Zhao X,Molenaar M,et al. Pattern Classification Approaches to Matching Building Polygons at Multiple Scales[C]//ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences,2012,I-2:19-24

[32] 陈哲. 基于OSM建筑物数据的自动变化探测:专家规则与机器学习对比研究[D]. 武汉:武汉大学,2019

[33] Selvaraju R R,Cogswell M,Das A,et al. Grad-cam: Visual Explanations from Deep Networks Via Gradient-based Localization[C]//Proceedings of the IEEE International Conference on Computer Vision,2017:618-626

（上接第43页）

技术将不动产测绘成果和相关地理信息空间数据进行融合和转换，自动快速构建具有实体化、三维化、语义化特征的不动产地理实体数据，可为不动产确权登记等管理工作提供直观、高效的数据服务。该方法效率高、实用性强，设计的FME模板可实现实体数据的一步自动构建。不足之处在于，暂时无法支持不符合“多测合一”入库标准的历史不动产测绘成果，需要人工干预。

参考文献

[1] 李峰. 三维不动产权籍测绘生产关键技术[J]. 测绘通报,2019(9):73-76

[2] 杨智文. 基于CityEngine的二三维联动三维地籍建模[J]. 测绘与空间地理信息,2019,42(2):158-161

[3] 张季一,尹鹏程,李钢,等. 基于共形几何代数的三维地籍空间数据建模探讨[J]. 地理与地理信息科学,2018,34(4):7-12

[4] 应申,郭仁忠,李霖 . 应用3DGIS实现三维地籍:实践与挑战[J]. 测绘地理信息,2018,43(2):1-6

[5] 苏鹰滨,葛莹 . 基于ArcEngine的三维地籍原型系统[J]. 地理空间信息,2018,16(1):107-109

[6] 自然资源部. 实景三维中国建设技术大纲[Z].

[7] 黎慧斌,郭艳. 不动产三维模型构建粒度的技术研究[J]. 地理空间信息,2019,17(6):107-108

[8] 陈琦,黄伟涛. 基于FME的城市更新基础数据自动化入库[J]. 地理空间信息,2019,17(7):57-59

[9] 自然资源部. 基础地理实体空间身份编码规则[Z].

[10] 孔庆福,杜熬. 基于不动产统一登记成果的三维管理研究[J]. 测绘通报,2017(增刊2):146-148

[11] 熊成利,龚旭峥,深正中,等. 不动产登记数据的建筑分层分户三维建模关键技术[J]. 测绘通报,2022(4):149-153

[12] 韦昭宁. 基于分层分户图的房屋内部三维模型的构建[D]. 桂林:广西师范学院,2011