引文格式：陈筱佑 ,巫建伟 ,宁小禾 ,等. 高空间分辨率遥感影像填海造地识别方法研究[J]. 地理空间信息, 2025, 23(1): 85-89. doi:10. 3969/j. issn. 1672-4623.2025.01.018

高空间分辨率遥感影像填海造地识别方法研究

陈筱佑[1]，巫建伟[2]，宁小禾[1]，王梦辰[1]，刘建华[1,3*]
（1. 北京建筑大学 移动地理空间大数据云服务创新团队 测绘与城市空间信息学院，北京 100044；2. 自然资源部第三海洋研究所，福建 厦门 361001；3. 城市空间信息工程北京市重点实验室 北京市测绘设计研究院，北京 100038）

摘　要：以空间分辨率为 0.54 m 的沿海地区卫星遥感影像为数据源，根据填海造地地块时序化监管的几何与光谱特征分析结果将其分类为围而未填、填而未用、已填已用（有建筑设施）3 种类型，构建与海岸线填海造地影像目标类型适配的谱系化深度学习特征样本库；再利用训练的多尺度粒度实例分割网络模型（MS-CNN）对该类地块进行识别，同时对比 2012—2022 年 3 个局部区域的变化影像图，以分析填海造地不同时期的识别效果。结果表明，MS-CNN 能较好地识别填海造地，地块识别结果精确率为 93.26%，召回率为 91.73%，F1-score 为 92.5%，提高了填海地块全局和局部尺度粒度的特征表达能力，改善了光谱异质性高等因素导致的多尺度共生目标错漏检问题，为填海造地识别监测提供了一种准确可行的方法。

关键词：填海造地；沿海地区；深度学习；高分辨率遥感影像；多尺度识别
中图分类号：P237　　**文献标志码：**B　　**文章编号：**1672-4623（2025）01-0085-05

Identification Method of Reclaimed Land from High-resolution Remote Sensing Images

CHEN Xiaoyou[1], WU Jianwei[2], NING Xiaohe[1], WANG Mengchen[1], LIU Jianhua[1,3]
(1. Mobile Geospatial Big Data Cloud Service Innovation Team, School of Geomatics and Urban Spatial Information, Beijing University of Civil Engineering and Architecture, Beijing 100044, China;
2. Third Institute of Oceanography, Ministry of Natural Resources, Xiamen 361001, China;
3. Beijing Institute of Surveying and Mapping, Beijing Key Laboratory of Urban Spatial Information Engineering, Beijing 100038, China)

Abstract: In this study, we took the satellite remote sensing images of coastal area with a spatial resolution of 0.54 m as the data source, and classified the reclaimed land parcels into three types, such as fenced but not filled, filled but not used and filled but used (with construction facilities), according to the geometric and spectral characteristics of temporal regulation of reclaimed land parcels. And then, we constructed a spectral deep learning feature sample library to match with the target type of reclaimed land parcels on the coastline image, and used a multi-scale granularity segmentation network model (MS-CNN) to identify this type of land parcels. Finally, we compared the image maps of three local areas from 2012 to 2022 to analyze the recognition effect of reclaimed land in different periods. The results show that MS-CNN can better identify the reclaimed land as a whole, with the precision rate reaching 93.26%, the recall rate reaching 91.73%, and the F1-score reaching 92.5%, which improves the feature expression ability of reclaimed land at both global and local scale granularity, improves the problem of wrong and omission detection of multi-scale coexistence targets caused by the factors such as high spectral heterogeneity, and provides an accurate and feasible method for reclaimed land identification monitoring.

Key words: reclaimed land, coastal region, deep learning, high-resolution remote sensing image, multi-scale identification

海岸线作为陆地和海洋的分界线，地貌类型复杂、资源种类丰富多样。在沿海经济带快速发展和全球气候变化等作用下，我国海岸带地区面临着生态系统功能受损、水体环境恶化、自然灾害频繁发生等问题[1]。填海造地将直接造成海岸线变迁，导致沿海栖息地丧失、物种多样性减少、区域水动力变化、生态系统服务功能丧失等生态环境问题。

遥感技术具有监测范围广、获取信息量大、可实现全面监测等优势[2]，是近年来海岸线填海造地变迁研究的主要手段。填海造地目标检测多采用传统边缘

项目来源：北京市测绘设计研究院城市空间信息工程北京市重点实验室资助项目（20220112）；北京建筑大学教育科学研究重点资助项目（Y2111）；北京市高等教育学会重点资助项目（ZD202244）；遥感科学与技术专业面向对象程序设计实习课程拔尖创新人才培养实践基地建设航天宏图信息技术股份有限公司资助项目（230902313215719）。
第一作者简介：陈筱佑（2002—），本科，研究方向为遥感应用技术，E-mail：76424677@qq.com。
通信作者：刘建华（1981—），博士，副教授，硕士生导师，研究方向为地理信息科学与遥感应用技术，E-mail：liujianhua@bucea.edu.cn。

检测算法，提取的边缘模糊导致无法呈现细节特征[3-4]，而基于深度学习的方法能通过大量特征学习，更准确地检测目标。刘晓芳[5]在海岸线提取上引入多层级深度神经网络HED，该网络结构在VGG-16和FCN网络的基础上进行了改进，用于提取遥感图像复杂场景中的边界信息；董晓冬[6]将形态学图像处理技术与富卷积特征提取技术相结合，利用RCF边缘检测算法提取海岸水边线；明生等[7]基于Landsat8遥感影像，利用轻量级深度学习模型LaeNet对海岛进行区域分割和边界提取；徐欣冉[8]通过调整隐层结构、引入VGG-16特征提取网络、添加空间置弃层、调试超参数等方法优化深度学习U-Net网络模型，使其适用于海岛海岸带目标地物识别检测。很多学者利用卷积神经网络对模型进行了优化[9-11]，其中Mask R-CNN[12]是在Faster R-CNN的基础上引入RoI Align层，通过双线性插值得到采样点位置的特征值，避免了量化的过程，提高了目标检测效果，使算法满足语义分割任务的精度要求。Lin T Y等[13]提出的特征金字塔网络（FPN）是多尺度模型中的经典网络结构；Gao S H等[14]提出的Res2Net，通过在基本残差单元构建一个类似的残差层，以增加每一层网络的感受野，提高多尺度特征表达能力；刘恒恒等[15]提出了一种新的网络DenseASPP-Unet，以U-Net模型为基础，实现了影像多尺度特征融合，提高了深度学习方法建筑物提取的精度；Liu Y等[16]提出的多尺度粒度实例分割网络模型（MS-CNN），基于遥感图谱理论对几何光谱特征进行学习，通过特征分割机制和叠加增强尺度特征融合策略，进一步提高了识别精度。传统的基于光谱特征和像素局部特征的海岸线识别和提取方法在面对高分辨率遥感图像复杂的纹理和空间分布时具有极大局限性，将导致分割不准确问题。只有在视觉特征和几何形态上对地理实体进行精准识别与提取，才能通过地理综合途径对高分遥感影像反映的地理实体所形成的地理现象进行更深入的分析。因此，如何克服传统遥感信息识别提取方法的缺点和局限性，寻求一种简便快捷的填海造地图斑识别方法至关重要。综上所述，本文结合填海造地实际监管业务需求和学科前沿，兼顾填海造地的几何、光谱、纹理等多尺度特征参数表征，提出了一种基于MS-CNN[16]模型的海岸线填海造地识别方法，以满足填海造地实际业务的需求。

1 填海造地地块时空特征分析

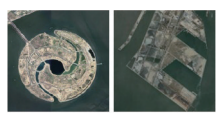
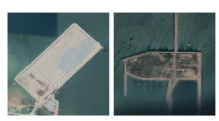
根据填海造地时空发展过程和不同时期遥感监测执法的业务要求，本文对填海造地地块的影像目标进行特征分析，并按照地块语义影像目标常规特征和现实意义将填海造地类型划分为围而未填、填而未用、已填已用（有建筑设施）3种类型（表1）。

表1 填海造地时序划分的地块类型

类型	地块影像目标图示	目视解译特征
围而未填		地块内部与邻接水域光谱特征基本一致，且尚未填埋渣土；围堰在水域中有较明显的线性边界，呈亮灰色
填而未用		地块内部已填满渣土，且与陆地连接，边界与海水毗邻；地块闲置内部有/无植物生长，分别呈深绿色/偏灰色[17]
已填已用		地块内部光谱异质性较大，建筑物几何形态各异；地块边界平直凸出陆地，且边界与海水毗邻

由于填海造地语义影像目标地物的类内差异包括几何、光谱、纹理特征，根据这些特征可较明确地区分其与周围易混淆的地物（表2）。

表2 填海造地的地块特征分析

目视特征	地块影像目标图示	目视解译特征
几何特征		形状相对规整，呈块状分布，长宽比不超过3∶1，连片布置，整体规模较大，内部分布建筑物、裸土等[3]；多呈有规则的条带状、块状多边形沿岸顺岸筑堤闭合面[18]；可独立于浅海中形成人工岛，但多数与大陆海岸连接
光谱特征		主要体现在围填基岩的光谱特征上，岩石种类各异，受环境条件影响，光谱特征异质性较大；浅色岩石反射率偏高，呈浅色调；深暗色岩石呈深灰到灰黑色色调，易受地表覆盖物（植被）影响
纹理特征		地块内部纹理与不同时空发展阶段地表覆盖有关，如裸地、植被、建筑物等，形成特殊的纹理结构

2 海岸线填海造地识别方法

2.1 MS-CNN模型概述

本文面向高分遥感影像海岸线填海造地识别需求，针对高分遥感影像填海造地地块多尺度共生和光谱异质性等主要问题，采用基于FPN[13]和Res2Net[14]的多尺度表征能力来优化Mask R-CNN所构建的MS-CNN模型，再结合填海造地时空特征分析构建地块谱系化样本库（集），同时构建高分遥感影像海岸

线填海造地识别技术流程体系。

MS-CNN模型[16]以Mask R-CNN实例分割网络模型[12]为底层基础架构，结合Res2Net[14]的多尺度粒度层级结构改进特征提取机制，构建多尺度表达能力的深度卷积神经网络，以提高填海造地的识别精度。MS-CNN模型总体分为3个部分：①共享卷积主干网络，改进了Mask R-CNN[12]卷积主干网络中的残差网络基本单元，更细粒度的残差分层结构增强了网络多尺度特征表征能力；②区域提议网络（RPN），将上一部分提取的特征图输入RPN生成区域候选框Proposals，修正感兴趣区（ROI）的候选框，再将生成的目标候选框输入RoIAlign层，使得每个ROI取得的特征更好地对齐原图ROI区域，并将其维度转换成一个固定值作为后续全连接层的输入；③分类、边框回归和掩码生成3个并行分支。MS-CNN模型[16]构建了一种多尺度卷积残差块，即在传统卷积残差块中引入尺度参数，通过多尺度网络在维度层面上对输入特征进行分割，并对分割后不同的特征子集进行卷积操作，可扩大并获得不同的感受野，同时特征子集之间层叠相加的连接使每一次卷积都能接收到前一组的特征信息，以提高卷积神经网络在具有不同维度输入和输出时以更细粒度的水平表达多尺度特征的能力。本文利用MS-CNN模型融合深层语义信息和浅层空间几何细节信息的优势，在网络深化中减少了浅层特征信息的损失，以增强高分辨率遥感影像海岸线填海造地地块的识别效果。在识别海岸线填海造地的过程中，MS-CNN模型的多尺度表征能力在扩大感受野完整获取大尺度目标特征的同时，增强了空间细节特征的表达，以提高小尺度目标信息获取的能力，实现填海造地相关地块语义影像目标的精准获取。

2.2　精度评价指标

本文采用精确率（Precision）、召回率（Recall）和F1-score三个指标来评价识别模型的精度。Precision用于衡量分类器预测正例的精确程度，本文中指正确识别为填海造地占识别为填海造地实例数量的比例；Recall用于衡量分类器覆盖正例的能力，本文中指正确识别为填海造地占填海造地实例数量的比例；F1-score为Precision和Recall的加权平均，用以评估模型的整体性能。

$$\text{Precision}=\frac{TP}{TP+FP}$$

$$\text{Recall}=\frac{TP}{TP+FN}$$

$$F_1=\frac{2\times\text{Precision}\times\text{Recall}}{\text{Precision}+\text{Recall}}$$

式中，TP（真正类）为模型正确识别为填海造地的样本数量；FP（假真类）为模型将背景错误识别为填海造地的样本数量；FN（假负性）为模型将填海造地错误识别为背景的样本数量。

3　实验与结果分析

3.1　实验数据

高空间分辨率遥感影像包含更加丰富的几何、光谱、纹理特征，能更加精确地表达地表地物。实验采用的高空间分辨率遥感影像数据为沿海地区遥感卫星影像，空间分辨率为0.54 m。为将高分遥感影像转化为MS-CNN模型能够进行地物目标识别的影像，需进行图像分幅预处理。在保证图像细节特征的前提下，对遥感影像进行双边滤波预处理，以达到去噪和增强图像边缘特征的效果，提高目标识别精度。

3.2　实验方法

3.2.1　谱系化样本库（集）构建

本文根据填海造地不同时期的几何、纹理和光谱等特征（表3），采集适合的样本数据构建与海岸线目标区域适配的谱系化样本库（集）。在预处理后的影像上沿目标轮廓标注地物类别、特征和位置信息，提取填海造地地物样本。在标注时要注意遮挡、阴影、填海造地靠近内陆易混淆等干扰因素。通过解析样本文件生成地物属性和掩码信息，提取目标地物样本属性获取真实准确的地面实况信息，生成训练模型所需的谱系化样本数据集。

3.2.2　填海造地识别方法

本文将高分辨率遥感影像谱系化样本库（集）随机划分为训练数据集（102个样本）、验证数据集（10个

表3　填海造地时序划分的地块类型

几何特征	原始影像	地物标签	光谱特征	原始影像	地物标签	纹理特征	原始影像	地物标签
条带状			浅色调			裸地		
块状			深色调			建设用地		

样本）和测试数据集（53个样本）。首先基于训练数据集训练MS-CNN模型并获取初始化参数，通过对模型同一参数取不同值拟合得到尺度参数化的多个识别模型；然后在验证数据集上采用不同尺度粒度评估每个参数化模型的精度，并根据模型精度评价结果对网络深度和尺度粒度进行调整，选择效果最佳的网络结构和尺度粒度对应的超参数；最后在测试数据集上进行填海造地识别，以验证方法的可行性和准确性。本文采用的网络结构和参数见表4，超参数见表5。

表4 多尺度卷积神经网络结构

Conv1	Conv2_x	Conv3_x	Conv4_x	Conv5_x
$[7\times7,64]$	$\begin{bmatrix}1\times1,64\\3\times3,64\\1\times1,256\end{bmatrix}\times3$	$\begin{bmatrix}1\times1,128\\3\times3,128\\1\times1,512\end{bmatrix}\times14$	$\begin{bmatrix}1\times1,128\\3\times3,128\\1\times1,512\end{bmatrix}\times16$	$\begin{bmatrix}1\times1,512\\3\times3,512\\1\times1,2\,048\end{bmatrix}\times3$

表5 超参数表

参数	参数类型	参数值
GPU_COUNT	采用的GPU数量	1
IMAGES_PER_GPU	每个GPU上训练的图像数量	1
BACKBONE	主干网络	Res2Net+FPN
BACKBONE_STRIDES	基于主干网络的降采样倍数，用于FPN	[4,8,16,32,64]
NUM_CLASSES	训练数据集中的类别数量（包括背景）	2
RPN_ANCHOR_SCALES	p2-p6每个特征图对应的锚框尺寸	(32,64,128,256,512)
RPN_ANCHOR_RATIOS	锚框每个尺寸对应的3种比例	[0.5,1,2]
RPN_NMS_THRESHOLD	非极大值抑制的阈值	0.7
TRAIN_ROIS_PER_IMAG	每幅图像为后面分类和掩膜网络输入的ROI个数	200
MAX_GT_INSTANCES	一幅图像中最多的实例数量	200
DETECTION_MAX_INSTANCES	最终检测包含的实例最大量	200
Batch Size	每次训练的图像数量	1
Epochs	迭代次数	30
LEARNING_RATE	学习率	0.000 1
LEARNING_MOMENTUM	学习动量	0.9
WEIGHT_DECAY	权重衰减	0.000 1

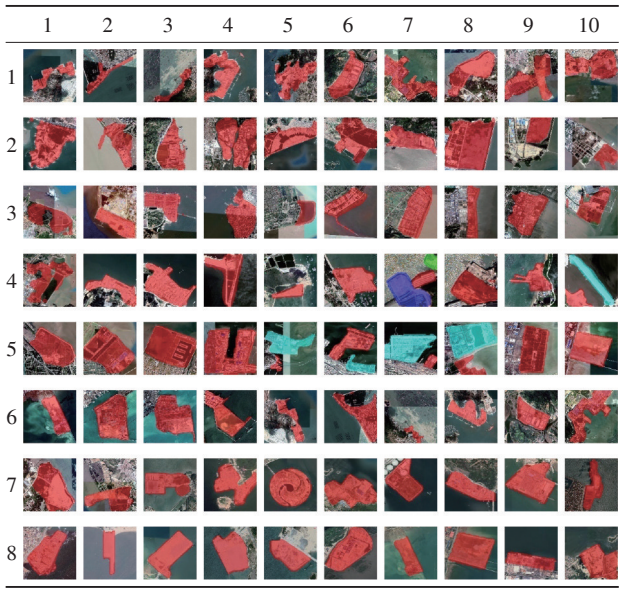
3.3 实验结果

利用改进后的MS-CNN模型对目标区域进行填海造地识别，获得含有目标掩膜的80张图像（表6）。对获得的填海造地目标识别结果进行精度评价，结果表明，Precision、Recall和F1-score分别达到了93.26%、91.73%和92.5%，证明MS-CNN模型在高分辨率遥感填海造地识别中具有良好的性能和模型泛化能力。

3.4 结果分析

面向高分辨率遥感影像填海造地的识别实验证明了MS-CNN模型的可行性和有效性。基于MS-CNN模

表6 填海造地测试集识别结果



型的填海造地识别结果的Precision达到93.26%，错检现象较少，预测的填海造地较准确。已填裸土或已填有建筑类型的填海造地存在与邻接陆地光谱特征较相似的情况，导致漏检现象，但因其边界平直沿海凸出陆地，有较明显的区分特征，且填海造地多为大尺度地物目标，因此取得了91.73%的Recall和92.5%的F1-score，再辅以人工质检环节，总体上能达到工程化生产的要求。此外，识别的部分目标掩码与实际填海造地几何形态在边界上仍有一定的偏差，这是未来需在几何形态上继续优化的方向。

从实验结果影像中选取吉钓岛西侧海域、福建省莆田市涵江区兴化湾南岸湾顶和连云港港赣榆港区3个局部区域影像，对比分析了2012—2022年3个区域变化影像图和识别结果。结果表明（表7），对于围而未填区域的识别，存在漏检和将邻接陆地一起识别的情况；已填裸土和已填有建筑的填海造地形状规整，与邻接陆地区别明显，虽然部分边界不够光滑，

但可以较好地识别填海造地整体区域。

表7　局部区域2012–2022年变化影像图与识别结果

吉钓岛西侧海域	识别结果	福建省莆田市涵江区兴化湾南岸湾顶	识别结果	连云港港赣榆港区	识别结果
					
					
					
					

4　结　语

本文提出了一种基于MS–CNN模型的填海造地识别方法，通过逐层特征分割和增强特征融合策略提高多尺度特征信息的表达能力。基于沿海地区高分辨率遥感影像数据（空间分辨率为0.54 m），根据填海造地几何、纹理、光谱特征构建了面向深度学习的填海造地谱系化时空特色样本库。利用MS–CNN模型进行填海造地目标识别，取得了93.26%的Precision、91.73%的Recall和92.5%的F1–score，验证了高分辨率遥感填海造地多尺度识别方法工程化的可行性、精度以及泛化能力。该方法提高了全局和局部尺度粒度的特征表达能力，能改善光谱异质性高等因素导致的多尺度共生目标错漏检问题，为填海造地自动化解译提供更有效的方法。

该方法识别模型输出的填海造地实例分割结果通常呈锯齿状，与实际边界存在一定几何形态偏差，因此在深度神经网络中增加填海造地轮廓正则化处理等方法来优化轮廓生成是今后的发展方向；同时还需进一步丰富特征谱系，构建更加完善的谱系化填海造地特征样本库，以提高目标识别结果的精确性。

参考文献

[1]　骆永明. 中国海岸带可持续发展中的生态环境问题与海岸科学发展[J]. 中国科学院院刊,2016,31(10):1 133-1 142

[2]　郑秀菊. 遥感技术在环境监测中的应用[J]. 科技资讯,2022,20(2):95-97

[3]　吴军超,李利伟,胡圣武. 基于多分类器集成的GF-1影像围填海地物识别[J]. 国土资源遥感,2017,29(1):143-148

[4]　Meng Y, Cao Y, Tian H, et al. The Identification of Land Utilization in Coastal Reclamation Areas in Tianjin Using High Resolution Remote Sensing Images[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences,2018,42:1 275-1 277

[5]　刘晓芳. 基于深度学习的遥感图像海岸线提取和地物分类[D]. 厦门:厦门大学,2017

[6]　董晓冬. 基于深度学习模型的海岸线提取及地物分类研究[D]. 广州:广东工业大学,2020

[7]　明生,张永林,谢荣安. 基于深度学习的海岛区域分割和海岸线提取[J]. 地矿测绘,2021,37(4):17-20

[8]　徐欣冉. 基于深度学习的海岛海岸带遥感影像地物分类算法研究[D]. 徐州:中国矿业大学,2022

[9]　He K, Zhang X, Ren S, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2015,37(9):1 904-1 916

[10]　Girshick R. Faster R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision, 2015:1 440-1 448

[11]　Ren S, He K, Girshick R, et al. Faster R-CNN: Towards Real-time Object Detection with Region Proposal Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(6):1 137-1 149

[12]　He K, Gkioxari G, Dollár P, et al. Mask R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision,2017:2 961-2 969

[13]　Lin T Y, Dollár P, Girshick R, et al. Feature Pyramid Networks for Object Detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017:2 117-2 125

[14]　Gao S H, Cheng M M, Zhao K, et al. Res2Net: A New Multi-scale Backbone Architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2019,43(2):652-662

[15]　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

[16]　Liu Y, Liu J, Ning X, et al. MS-CNN: Multiscale Recognition of Building Rooftops from High Spatial Resolution Remote Sensing Imagery[J]. International Journal of Remote Sensing,2022,43(1):270-298

[17]　柯丽娜,曹君,武红庆,等. 基于多源遥感影像的锦州湾附近海域围填海动态演变分析[J]. 资源科学,2018,40(8):1 645-1 657

[18]　岳昂. 面向对象的海岸带用海地物遥感分类规则研究[D]. 天津:天津师范大学,2013