

引用格式: Yu Fengshi, Sui Yi, Wang Changying, *et al.* Reclamation Detection and Recognition of High Resolution Satellite Remote Sensing Image based on Deep Learning[J]. Remote Sensing Technology and Application, 2022, 37(4): 789-799. [于枫世, 隋毅, 王常颖, 等. 基于深度学习的高分辨率卫星遥感影像围填海检测识别[J]. 遥感技术与应用, 2022, 37(4): 789-799.]
DOI: 10.11873/j.issn.1004-0323.2022.4.0789

基于深度学习的高分辨率卫星遥感影像围填海检测识别

于枫世¹, 隋毅¹, 王常颖¹, 初佳兰²

(1. 青岛大学计算机科学技术学院, 山东 青岛 266071;

2. 国家海洋环境监测中心, 辽宁 大连 116023)

摘要: 基于高分辨率卫星遥感影像自动、准确提取围填海土地利用现状, 是实现围填海集约使用的重要技术手段。针对高分辨率卫星遥感影像地物特征复杂, 依赖人工提取特征的传统方法较难满足业务部门实际需求的问题, 提出了基于深度学习的围填海检测识别技术框架, 该框架使用U-Net网络的多约束变体结构, 并针对高分辨率遥感影像地物特征复杂导致地物分类不一致的问题, 引入全连接条件随机场和图像腐蚀运算对分割结果进行后处理。以天津市滨海新区2016年和2020年高分辨卫星遥感影像为数据源进行了验证, 实验表明围填海地物分割整体准确率、F1-score、Kappa系数以及mIoU分别达到96.73%、92.87%、90.28%、86.82%。在此基础上, 分析提取了该围填海区域土地利用动态变化特征, 为围填海集约使用管理提供了有效技术支撑。

关键词: 围填海; 深度学习; 检测识别; U-Net

中图分类号: P756.8 **文献标志码:** A **文章编号:** 1004-0323(2022)04-0789-11

1 引言

围填海集约使用是指最大程度地提高已围、已填土地的利用率, 避免围而不填、填而不建以及土地的低效使用。集约使用围填海土地, 不仅能够充分利用已有资源, 还能避免盲目围填海, 是实现海洋生态环境保护的重要途径^[1]。近年来, 我国沿海地区围填海土地利用率较低的问题十分突出, 填而未用、长期空置已成为部分省市的共性问题, 快速、准确地掌握围填海土地利用现状, 实时监测分析围填海土地利用变化情况, 已成为海域动态监视监测的重要内容^[1-3]。

利用高分辨率卫星遥感影像自动获取围填海

资源利用现状及动态变化信息, 取得了较多研究成果, 主要解决思路是人工提取围填海地物的光谱、形状和纹理等特征, 使用面向对象^[4-6]、决策树分类^[7-9]、支持向量机^[10-12]等方法, 对围填海区域进行分割和类型识别。这些方法的识别效果极大地依赖于人工提取特征的准确性, 由于高分辨率遥感影像的纹理和形状特征十分复杂, 人工提取耗费大量时间, 不仅分割和识别精度易受主观因素影响, 而且较多的人工参与很难满足业务部门的业务自动化的实际需求。

近年来, 随着深度学习技术快速发展, 越来越多的学者将深度学习方法应用于遥感图像处理领域。卷积神经网络(Convolutional Neural Network,

收稿日期: 2020-08-31; 修订日期: 2021-09-07

基金项目: 国家自然科学基金青年基金项目(41706198、41706105), 国家自然科学基金面上项目(41876109), 山东省高等学校科技计划项目(J17KA056)。

作者简介: 于枫世(1997—), 男, 山东烟台人, 硕士研究生, 主要从事遥感图像处理。E-mail: 2019020589@qdu.edu.cn

通讯作者: 隋毅(1984—), 女, 山东青岛人, 博士, 副教授, 主要从事数据挖掘、机器学习、复杂网络方面的研究。E-mail: suiyi@qdu.edu.cn

CNN)^[13],通过卷积和全连接层自动提取图像特征并分类,相比传统方法取得了更高的精度。曹林林^[14]通过实验对比分析,证明了卷积神经网络在高分辨率遥感影像分类中的可行性和精度优势。全卷积神经网络(Full Convolution Network, FCN)^[15]用上采样层替换了CNN的全连接层,通过结合不同深度的下采样层信息衍生出不同的FCN结构。U-Net^[16]采用编解码结构改进FCN,在编码阶段使用卷积层和最大池化层不断下采样,由浅入深提取图像语义特征,在解码阶段采用转置卷积逐层恢复特征图的细节层次信息,并在编码和解码的对应层间添加跳跃连接结构,增强上下采样层间的信息交流。已有研究表明,U-Net在遥感影像地物分割应用中的表现优于基于人工提取特征的方法。苏健民等^[17]针对遥感图像分割问题提出一种基于U-Net改进的深度卷积神经网络,并证明该网络在拥有较高分割准确率的同时还具有良好的泛化能力,能够用于实际工程。徐慧敏^[18]研究了深度学习的U-Net模型进行高分辨率遥感影响分类的方法,使用多种数据与原图像进行结合,使模型学习到更丰富的特征从而提高了分类精度。Chaurasia等^[19]采用了类似U-Net的跳跃连接结构,并将其编码器的特征提取块修改为残差结构提出LinkNet模型,提升了特

征提取的能力。Li等^[20]使用具有残差块的U-Net网络基于Sentinel-1 Sar数据集对城市建筑物进行变化检测。根据BP反向传播算法,离输出层越远,参数的更新就越慢,虽然参数批量归一化(Batch Normalization, BN)^[21]能够缓解这一问题,但仍有改进空间。Wu等^[22]将U-Net解码阶段各中间层的输出融入到损失函数最小化求解中,能够直接优化中间层参数,使模型能够更好收敛,同时由于各中间层输出的特征图蕴含了图像多尺度的信息,很好地提升了U-Net分割精度,实验将该方法应用于围填海地物的分类,并针对高分辨率遥感影像地物特征复杂导致地物分类不一致的问题,引入全连接条件随机场和形态学腐蚀运算对分割结果进行后处理,构建了基于深度学习的围填海地物检测技术框架,以天津市滨海新区高分辨遥感影像为数据源,分析提取了2016年和2020年围填海区域土地利用动态变化特征,验证了本方法的有效性,为围填海集约使用管理提供了有效的技术支持。

2 研究方法

2.1 U-Net网络及其多约束变体结构MCFCN

U-Net结构如图1所示,编码阶段每层通过卷积自动提取图像特征,使用最大池化进行下采样缩




图1 经典U-Net网络结构^[16]

Fig.1 Classic U-Net network structure^[16]

小特征图并增加通道数,随着网络加深不断提取图像的高层语义特征,神经元激活函数选取 ReLu,使用 BN 对参数预处理防止梯度消失提高网络的收敛速度。解码阶段使用反卷积进行上采样增大特征图,跳跃连接将编码器的特征融合到解码器中帮助解码器恢复特征图的细节信息,最后通过 1×1 的卷积将多通道图像转换为特定的深度(分类数),使用交叉熵损失函数最小化预测结果与真值(ground truth)之间的差值。U-Net 不限制输入图像的尺寸,可以根据实际情况调整图像的大小,使用起来更加灵活方便。

Wu 等^[22]对 U-Net 网络的损失函数进行了改进,提出了多约束的网络结构 MCFCN(Multi-Constraint Fully Convolutional Networks),如图 2 所示。

该结构不仅考虑解码阶段最后一层的损失,还考虑了中间层与其对应的不同尺度 ground truth 间的损失,损失函数如公式(1)和(2)所示,其中 C_{main} 表示最后一层输出与 ground truth 之间的损失, C_{subx} ($x=1, 2, 3$) 表示解码阶段中间层 x 和 ground truth 下采样 $1/2^x$ 大小之间的损失, α, β, γ 和 δ 分别为各层约束的权重,并且 $\alpha + \beta + \gamma + \delta = 1$ 。 W^k, H^k 为图像的宽和高, $g^k_{i,j}$ 为该处像素的预测值, $y_{i,j}$ 为该处像素的真实值。下采样的 ground truth 使用双线性插值得到, C_{main} 和 C_{subx} 使用交叉熵损失函数计算。

$$Loss = \alpha * C_{main} + \beta * C_{sub1} + \gamma * C_{sub2} + \delta * C_{sub3} \quad (1)$$

$$C_{subx} = -\frac{1}{W^k * H^k} * \sum_{i=1, j=1}^{W^k, H^k} g^k_{i,j} * \log(y^k_{i,j}) + (1 - g^k_{i,j}) * \log(1 - y^k_{i,j}) \quad (2)$$




图2 多约束变体 U-Net(MCFCN)网络结构

Fig.2 Multi constrained variant U-Net (MCFCN) network architecture

2.2 基于条件随机场和形态学腐蚀的分割结果后处理

网络预测的结果会产生分割边界模糊的现象,这是由于特征图在经过上采样的过程中造成了特征损失。已有研究表明,引入全连接条件随机场(Conditional Random Field, CRF)对分割结果进行后处理可以优化结果中粗糙和不确定的标记,增强对物体边界的定位。Chen 等^[23]对 FCN 添加全连接条件随机场提出了 Deeplab 模型,结合上下文信息

提高了分割精度。Bittner 等^[24]使用 FCN 对遥感图像中的建筑物分割,使用全连接条件随机场对结果修正,显著改善了分割效果。

全连接 CRF 采用公式(3)所示的能量函数,其中一元势函数 $\theta_i(x_i) = -\log P(x_i)$, $P(x_i)$ 是像素 i 的预测值(由模型给出),二元势函数如公式(4)所示。

$$E(x) = \sum_i \theta_i(x_i) + \sum_{i,j} \theta_{ij}(x_i, y_j) \quad (3)$$

$$\theta_{ij}(x_i, y_i) = \mu(x_i, y_i) \left[w_1 \exp \left(-\frac{|p_i - p_j|^2}{2\sigma_a^2} - \frac{|I_i - J_j|^2}{2\sigma_\beta^2} \right) + w_2 \exp \left(-\frac{|p_i - p_j|^2}{2\sigma_\gamma^2} \right) \right] \quad (4)$$

当 $x_i \neq y_i$ 时 $\mu(x_i, y_i) = 1$, 否则 $\mu(x_i, y_i) = 0$, 其物理意义是惩罚具有不同标签的节点。中括号中第一个高斯核函数同时考虑像素的位置 (p_i, p_j) 和颜色 (I_i, J_j) 的关系, 使具有相同颜色的临近像素具有相同的标签, 第二个高斯核函数仅考虑像素的位置。

使用全连接 CRF 对结果做后处理的流程如图 3 所示, 其中一元势能来自模型的预测结果, 二元势能中颜色及位置相关信息来自原图像, 由高斯核函数创建与颜色无关的位置特征, 最后通过迭代最小化能量函数得到处理结果。




图 3 全连接 CRF 处理流程

Fig.3 Fully connected condition random field processing flow

如图 4(c) 所示, 经过全连接 CRF 处理后的结果, 边界模糊的问题得到改善, 但同时产生了一些细小的孔洞。针对此问题, 使用形态学腐蚀的方法先后对结果进行闭运算和开运算, 以填充孔洞并去除噪声。图 4(d) 中经过全连接 CRF 和形态学腐蚀后处理得到的结果边界清晰精度更高, 可以达到分析使用的标准。

2.3 基于 MCFCN 的围填海检测框架

将研究区域分为训练集和测试集, 对训练集和测试集使用滑动窗口的方法间隔固定的距离裁剪成规则的切片。从训练集中选取 30% 数据做验证集用于挑选最优训练模型, 使用训练得到的最优模型进行测试得到分割结果, 将分割结果拼接为完整




图 4 后处理结果对比

Fig.4 Comparison of post-processing results

的测试区域。对结果实施全连接 CRF 平滑和形态学腐蚀后处理得到最终结果。

根据分辨率信息计算像素值代表的实际面积, 以此来估算围填海区域土地变化和利用情况。具体流程如图 5 所示。

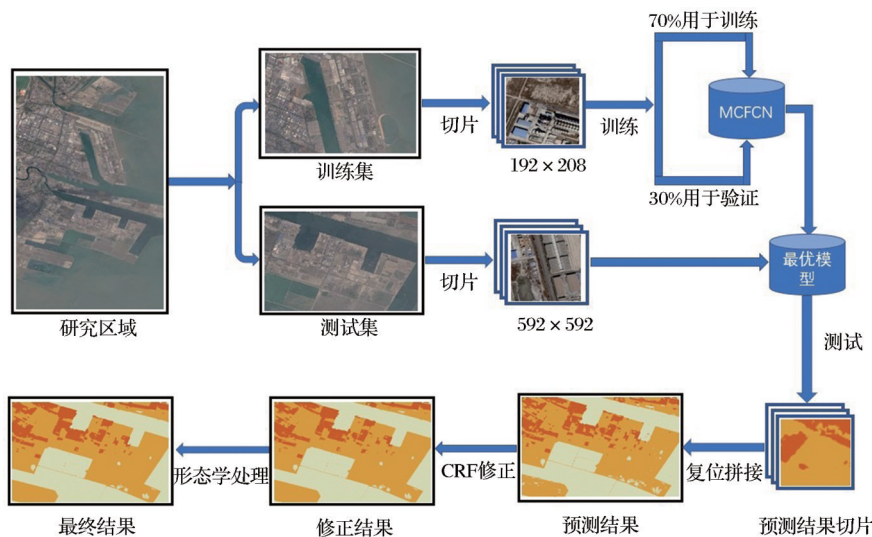


图 5 围填海检测流程图

Fig.5 Flow chart of reclamation land detection

3 研究区域与数据预处理

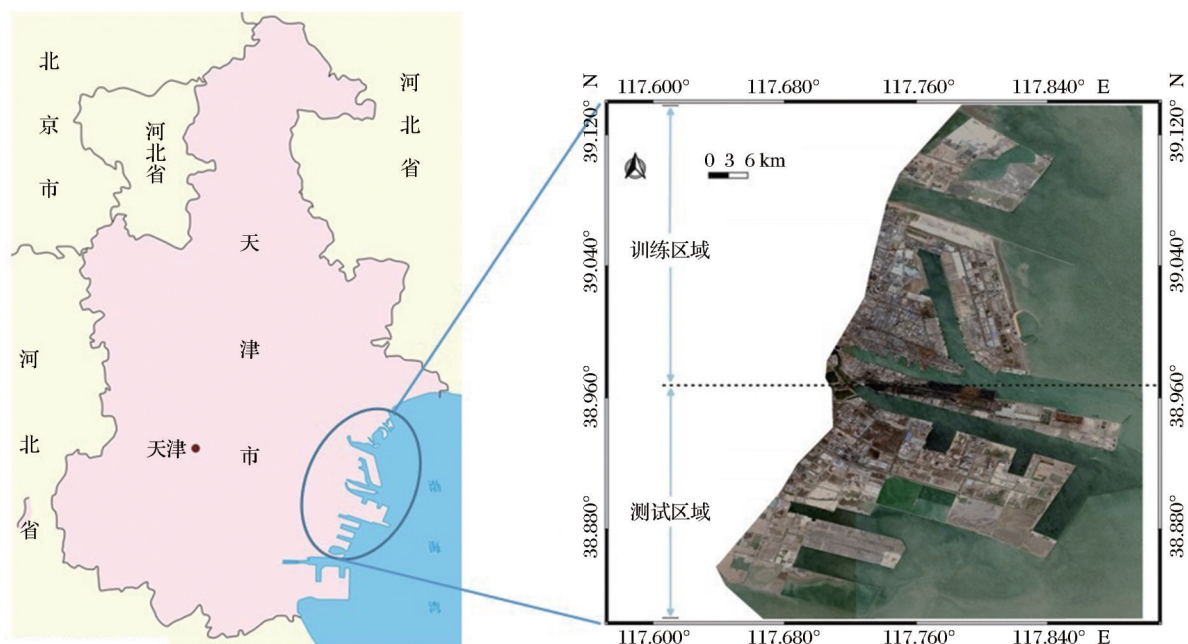
3.1 研究区概况

选取天津市滨海新区秦滨高速以东(如图6所示)的滨海旅游区、北疆港区、南疆港区、东疆港区、临港工业区作为研究区域,地理范围为 117.639°W — 117.897°E , 39.138°N — 38.826°S ,该部分围填海区域以城镇建设用地为主,获取该区域的围填海土地利用现状和不同年份土地利用变化情况具有较强的实际需求。

3.2 数据预处理

使用Google Earth 2016年3月10日和2020年3月23日获取的两景高分辨率遥感卫星影像,空间分

辨率为1.86 m,包含R、G、B 3个波段,使用ENVI 5.3软件对影像进行几何校正与辐射校正。影像区域被划分为训练区域和测试区域,两区域均含有居民区、工业园区、物流园区、港口等地物类型,由专家目视解译确定地物类型标记,将单一大型建筑的所在区域、多个空间临近的建筑形成的区域、港口、集装箱/货物堆场等地物标记为已利用土地。对有人工建造痕迹但不属于上述已利用土地的裸地,查看后时相影像,是否已变为已利用土地,若是,则为已利用土地,否则为未利用土地,若无后时相影像,则视为未利用土地,其他荒草地、沙地、盐碱地、裸土地等标记为未利用土地。



审图号:GS(2019)3266

图6 研究区域和测试集、训练集区域的划分

Fig.6 The division of research area, test set and training set area

使用2016年和2020年的数据制作训练集和验证集,原始数据为42张 $1\,457\times 971$ 像素Tif图像,结合模型参数量和GPU显存大小确定切片的大小为 192×208 像素,使用水平翻转和垂直翻转的数据增广方式将训练集扩充为原来的3倍。测试图像为两张2016年和2020年位于测试区域 $6\,640\times 4\,200$ 像素的Tif图像,为了减少因拼接产生的噪声应尽量选取较大的切片,因此切片大小设置为 592×592 像素。

4 结果与讨论

4.1 相关参数设置

实验平台配置: Intel(R) Xeon(R) W-2133 处

理器, 32GB 内存, NVIDIA GeForce GTX 1080Ti 显卡(GPU), 显存 11GB。使用的深度学习框架为pytorch, 影像矫正使用ENVI 5.3软件, 后处理使用的python工具包为pydensecrf和opencv-python。MCFCN模型参数设置, 学习率: 0.000 2, base_kernel: 24, Batch Size: 24, 训练轮次: 100, 每隔5个轮次使用验证集进行验证, 并保存准确率最高的模型。

(1)多尺度约束参数的选取: 考虑到不同约束位置对网络的影响, 约束参数选取如表1所示。

(2)全连接条件随机场后处理参数设置: 一元势置信度设置为0.5, 即50%确定网络预测结果是正确的, 二元势中位置特征的高斯核大小设为 2×2 ,

表 1 损失函数中约束参数选取
Table 1 Selection of constraint parameters in loss function

模型	α	β	γ	δ
MCFCN ₁	0.5	0.5	0	0
MCFCN ₂	0.5	0	0.5	0
MCFCN ₃	0.5	0	0	0.5
MCFCN ₄	0.25	0.25	0.25	0.25
MCFCN ₅	1	0	0	0

迭代次数为 8 次。

(3)形态学腐蚀后处理参数设置:针对条件随机场处理结果产生孔洞和噪声,闭运算和开运算核的大小分别为 15×15 和 11×11。

(4)分类结果评价指标选取:整体精准度(Overall Accuracy)^[25]、mIoU^[26]、Kappa 系数^[27]、F1-score。根据本文研究的问题,评价指标的计算基于已利用土地(正类)和未利用土地(负类),海洋作为背景不参与评价指标的计算。

4.2 最优模型选取

不同约束参数模型效果如表 2 所示。结果表明,添加多尺度约束的结果均优于不添加约束(MCFCN₅)的结果,并且实验表明,只在第一层和第三层添加约束可以达到最佳效果,因此 MCFCN 多尺度约束参数选取: $\alpha:\beta:\gamma:\delta=0.5:0:0.5:0$,因此以 MCFCN₂作为预测模型。

表 2 不同参数条件下验证集上模型性能比较
Table 2 Performance comparison of models on validation set under different parameters

模型	总体分类精度	F1-score	Kappa	mIoU
MCFCN ₁	0.972	0.944	0.924	0.895
MCFCN ₂	0.973	0.945	0.926	0.897
MCFCN ₃	0.972	0.942	0.923	0.892
MCFCN ₄	0.973	0.943	0.924	0.893
MCFCN ₅	0.971	0.940	0.920	0.889

使用 2016 年和 2020 年测试区域的遥感影像测试模型,不同模型评估指标对比如表 3 所示。其中,FCN8s、U-Net、Linknet 的超参数设置与 MCFCN₂一致。SVM 方法使用 ENVI 5.3 中的 SVM 有监督分类实现,核函数选取径向基核函数,并使用聚类处理平滑 SVM 结果。

测试结果显示,相比传统方法深度学习模型避免了因人为提取特征而导致的误差。MCFCN₂相比 U-Net 和 Linknet 在不同时相的各项评估指标上均取得了更优的结果,并且明显优于 FCN8s 和 SVM 算法,经过后处理可以进一步提升模型效果,整体准

确率可以提升 0.5% 左右,在 F1-score、Kappa 系数和 mIoU 上平均可以提升 1%—2%。

U-Net、Linknet 以及 MCFCN₂的参数量和训练速度对比如表 4 所示,FPS 表示每秒处理的图像数量。U-Net 结构简单,参数量最少训练速度最快,Linknet 由于使用了更复杂的编码器从而增加了参数量降低了训练速度,MCFCN₂添加下采样约束在提升性能的同时只增加了较少的参数。从模型效果和训练效率等方面分析,MCFCN₂更适合本文研究的问题。

表 3 测试区域结果比较
Table 3 Comparison of test area results

时间	模型	总体分类精度	F1-score	Kappa	mIoU
2016 年	SVM	0.913 6	0.723 6	0.657 9	0.605 0
	FCN8s	0.928 4	0.839 7	0.779 8	0.729 2
	U-Net	0.957 4	0.908 6	0.872 8	0.834 4
	Linknet	0.957 7	0.910 0	0.874 3	0.836 7
	MCFCN ₂	0.958 1	0.915 3	0.879 7	0.844 8
	MCFCN ₂ +后处理	0.962 1	0.924 3	0.892 0	0.860 1
2020 年	SVM	0.876 0	0.684 9	0.589 0	0.547 5
	FCN8s	0.931 7	0.844 0	0.789 9	0.735 8
	U-Net	0.955 5	0.905 5	0.870 4	0.829 1
	Linknet	0.955 7	0.904 0	0.869 4	0.826 9
	MCFCN ₂	0.961 2	0.914 1	0.883 5	0.843 7
	MCFCN ₂ +后处理	0.967 3	0.928 7	0.902 8	0.868 2

表 4 模型参数规模
Table 4 Model parameter scale

模型	参数量(10 ⁶)	训练速度(FPS)
UNet	3.408 9	94.77
Linknet	8.328 6	75.32
MCFCN ₂	3.414 8	88.31

不同方法测试结果对比如图 7 所示,SVM 对光谱较为复杂的码头、堆场等地物分类不连续容易产生碎块,导致分类精度降低。传统的全卷积神经网络 FCN8s 由于缺乏更细致的解码器和跳跃连接导致上采样信息恢复不充分,分类效果不如 U-Net。Linknet 通过优化 U-Net 的编码器增强特征提取以提升性能,MCFCN₂对不同上采样层添加约束效果提升更加明显,而且几乎不增加模型的复杂度。使用全连接 CRF 和形态学腐蚀对结果进行后处理对结果提升明显。

图 8 为后处理对比结果,使用全连接 CRF 对结果进行修正可以解决预测结果边界模糊的问题,还

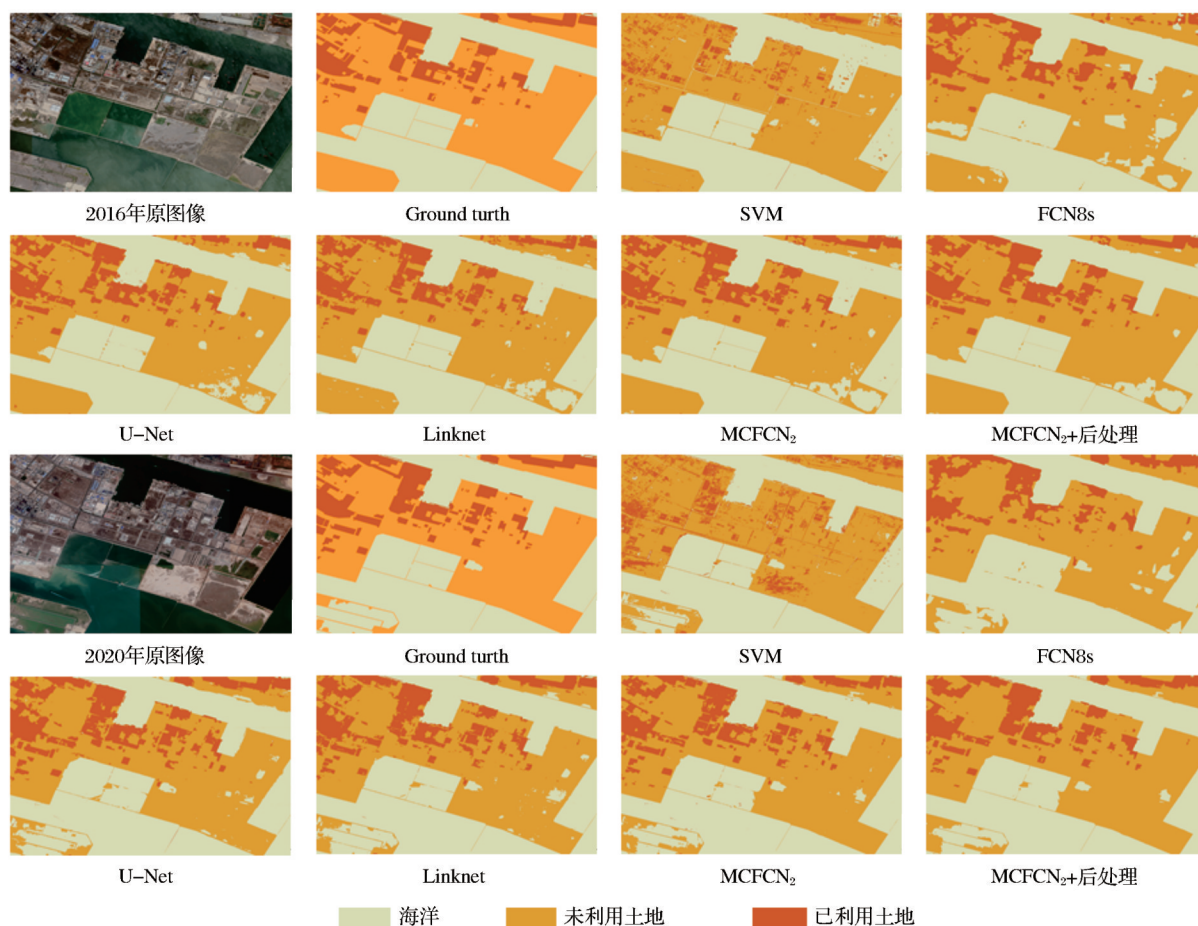


图7 2016年和2020年测试区域结果比较

Fig.7 Comparison of test area results between 2016 and 2020

可以起到纠正错误分类的作用,如图8(b)纠正了海洋中被错误分类的船只。使用形态学腐蚀处理优化全连接CRF的结果起到了填充孔洞和去除噪声的作用。

4.3 围填海土地利用现状与变化分析

影像空间分辨率为1.86 m,每个像素代表的实际面积约为4.355 m²,根据行政区划,将研究区域划分为6个子区,如图9(a)所示,根据划分的子区域对2016年和2020年研究区域围填海土地利用情况进行分析,两时像各港区已利用土地面积、未利用土地面积以及已利用土地占比情况见表5。

2016年和2020年陆地面积对比如图10(a),可知2016年以来天津市滨海新区基本没有围填海活动,2016年和2020年天津市滨海新区各港区土地利用变化如图10(b)所示。其中,滨海旅游区已利用土地面积增长了1.093 km²,相较于其他港区增幅最大,说明该区域虽处于发展的起步阶段,但是发展速度很快,而且新增已利用土地多为居住、旅游用途,可知该区域的建设中心偏向旅游与服务业。东

疆港区新增利用土地面积0.553 km²,主要来自居民区的扩建。东疆港区已利用土地主要分布于西南沿海,由大型码头和发达的物流业组成,东部沿海地区主要为景区(东疆湾景区)和居民公寓。2020年位于北疆港区新港五号路和新港六号路交会的大型堆场和新港一号路南部堆货码头的遗弃导致了北疆港区已利用土地面积的负增长。南疆港区已利用土地面积基本保持不变。由于北部沿海码头和南部工业区的扩建,临港工业区1已利用土地面积增加了2.17 km²。临港工业区2利用土地面积很少而且基本没有变化。

5 结 论

采用高分辨率遥感卫星影像自动准确地检测识别围填海土地利用状况是海洋管理部门的迫切需求。由于高分辨率卫星遥感影像地物特征复杂,基于人工提取特征的传统方法需要耗费大量人力物力,难以满足实际需求。基于此,提出了基于深度学习的端到端的围填海检测识别技术框架,该框架

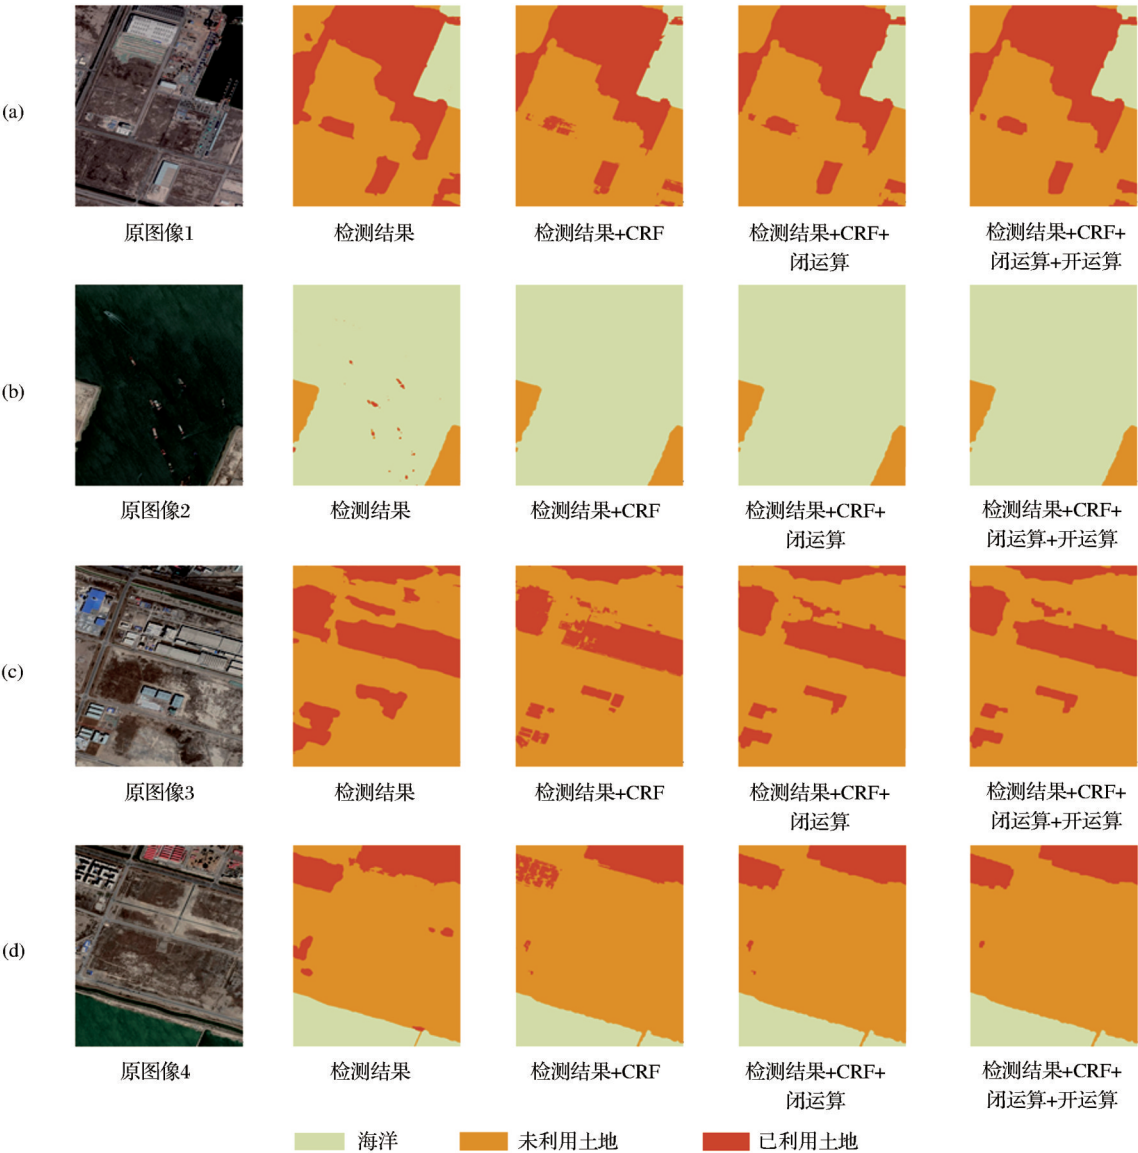


图 8 添加后处理结果比较

Fig.8 Comparison results after post-processing




图 9 2016 年和 2020 年研究区域划分及结果

Fig.9 Study area division and results in 2016 and 2020

审图号:GS(2019)3266

表 5 2016—2020 年各港区土地利用情况
Table 5 Land use change between 2016 and 2020

	2016 年			2020 年		
	已利用/km ²	未利用/km ²	已利用比例	已利用/km ²	未利用/km ²	已利用比例
滨海旅游区	0.464	22.376	2.03%	1.557	21.103	6.87%
东疆港区	10.239	25.684	28.50%	10.792	24.683	30.42%
北疆港区	25.476	4.702	84.42%	24.586	5.315	82.22%
南疆港区	15.421	11.002	58.36%	15.349	11.336	57.52%
临港工业区 1	15.670	56.712	21.65%	17.840	57.225	23.77%
临港工业区 2	0.420	28.696	1.44%	0.297	22.510	1.30%
整体	67.690	149.172	31.21%	70.421	142.172	33.12%




图 10 2016 年和 2020 年各港区陆地面积和利用土地面积
Fig.10 Land area and land use area in 2016 and 2020

使用 U-Net 网络的多约束变体结构,不需人工提取特征,而是通过数据自动学习提取,并针对高分辨遥感影像地物特征复杂导致地物分类不一致的问题,引入全连接条件随机场和形态学腐蚀运算对分割结果进行后处理。以天津市滨海新区 2016 年和 2020 年高分辨卫星遥感影像为数据源进行了验证,实验表明围填海地物分割整体准确率、F1-score、Kappa 系数以及 mIoU 分别可以达到 96.73%、92.87%、90.28% 和 86.82%,可满足业务部门的实际需求,为围填海土地集约使用管理提供了有效技术支撑。根据像素值估算滨海新区围填海及土地利用情况,发现该地区自 2016 年至 2020 年没有围填海活动,2016 年和 2020 年围填海土地利用率分别为 31.21% 和 33.12%,5 年间仅增长 1.91%,虽然呈上升趋势,但大部分港区土地利用率仍然较低。

参考文献 (References):

[1] Suo Anning, Wang Peng, Yuan Daowei, *et al.* Study on monitoring and analysis of existing sea reclamation resource based on high resolution satellite remote sensing imagery: A case in south coast of Yingkou[J]. *Acta Oceanologica Sinica*, 2016, 38

(9):54-63.[索安宁,王鹏,袁道伟,等.基于高空间分辨率卫星遥感影像的围填海存量资源监测与评估研究——以营口市南部海岸为例[J].*海洋学报*,2016,38(9):54-63.]

[2] Gao Ning, Du Xinyuan, Xu Peng, *et al.* Monitoring technology and method of doubtful area in reclamation area[J]. *Ocean Development and Management*, 2019, 36(2): 14-16.[高宁,杜新远,许鹏,等.围填海疑点疑区监测技术方法[J].*海洋开发与管理*,2019,36(2):14-16.]

[3] Sun Jing, Zhang Ying, Qiao Qinghua, *et al.* Reclamation project monitoring and ecosystem service value change analysis [J]. *Science of Surveying and Mapping*, 2020, 45(12): 201-208.[孙静,张英,乔庆华,等.围填海工程监测及生态系统服务价值变化分析[J].*测绘科学*,2020,45(12):201-208.]

[4] Jia Wei, Gao Xiaohong, Yang Lingyu, *et al.* Land cover information extraction for complicated terrain regions via an object-oriented classification method[J]. *Journal of Lanzhou University(Natural Sciences Edition)*, 2018, 54(4): 486-493.[贾伟,高小红,杨灵玉,等.面向对象方法的复杂地形区地表覆盖信息提取[J].*兰州大学学报(自然科学版)*,2018,54(4):486-493.]

[5] Ju Mingming, Wang Min, Zhang Dong, *et al.* Study on the remote-sensing-based monitoring of reclamation project area by using the object-oriented image analysis technique[J]. *Marine Science Bulletin*, 2013, 32(6): 678-684.[鞠明明,汪闽,张东,等.基于面向对象图像分析技术的围填海用海工程遥感监测

- [J]. 海洋通报, 2013, 32(6): 678-684.]
- [6] Zhou Tianya. Object-oriented land cover classification using high spatial resolution remote sensing[J]. Geomatics Science and Technology, 2020, 8(1): 9-16. [周天涯. 面向对象的高空间分辨率遥感土地覆盖分类[J]. 测绘科学技术, 2020, 8(1): 9-16.]
- [7] Rao Ping, Wang Jianli, Wang Yong, *et al.* Extraction of information on construction land based on multi-feature decision tree classification Extraction of information on construction land based on multi-feature decision tree classification [J]. Transactions of the Chinese Society of Agricultural Engineering, 2014, 30(12): 233-240. [饶萍, 王建力, 王勇. 基于多特征决策树的建设用地信息提取[J]. 农业工程学报, 2014, 30(12): 233-240.]
- [8] Zhang Hongmei, Wu Jiwen, Liu Xing, *et al.* Land use classification based on feature extraction and decision tree method [J]. Science of Surveying and Mapping, 2014, 39(10): 53-56. [张红梅, 吴基文, 刘星, 等. 特征提取和决策树法土地利用遥感分类[J]. 测绘科学, 2014, 39(10): 53-56.]
- [9] Zhang Qian. Research on land cover classification of aerial hyperspectral remote sensing based on decision tree method [D]. Jinan: Shandong University of Science and Technology, 2015 [张倩. 基于决策树方法的航空高光谱遥感土地覆盖分类研究[D]. 济南: 山东科技大学, 2015.]
- [10] Shen Zhaoqing, Huang Liang, Tao Jianbin. Hyperspectral RS image road feature extraction based on SVM [J]. Journal of Chang'an University (Natural Science Edition), 2012, 32(5): 34-38. [沈照庆, 黄亮, 陶建斌. 基于支持向量机的高光谱遥感影像道路提取[J]. 长安大学学报(自然科学版), 2012, 32(5): 34-38.]
- [11] Yuan Yongsheng. Research on object-oriented land cover image classification method based on support vector machine classification [D]. Xianyang: Northwest A&F University. [员永生. 基于支持向量机分类的面向对象土地覆被图像分类方法研究[D]. 咸阳: 西北农林科技大学, 2010.]
- [12] Zhu Jieer. Research on support vector machine classification of hyperspectral images combined with spatial information [D]. Hangzhou: Zhejiang University. [朱洁尔. 结合空间信息的高光谱图像支持向量机分类研究[D]. 杭州: 浙江大学, 2013.]
- [13] Le Cun, Yoshua Bengio. Convolutional networks for images, speech, and time series [J]. The Handbook of Brain Theory and Neural Networks, 1995, 3361(10): 255-258.
- [14] Cao Linlin, Li Haitao, Han Yanshun, *et al.* Application of convolutional neural networks in classification of high resolution remote sensing imagery [J]. Science of Surveying and Mapping, 2016, 41(9): 170-175. [曹林林, 李海涛, 韩颜顺, 等. 卷积神经网络在高分遥感影像分类中的应用[J]. 测绘科学, 2016, 41(9): 170-175.]
- [15] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 3431-3440. DOI: 10.1109/CVPR.2015.7298965.
- [16] Ronneberger O, Fischer O, Brox T. U-Net: convolutional networks for biomedical image segmentation [J]. Medical Image Computing and Computer-Assisted Intervention, Pt Iii, 2015, 9351: 234-241. DOI: 10.1007/978-3-319-24574-4_28.
- [17] Su Jianmin, Yang Lanxin, Jing Weipeng. U-Net based semantic segmentation method for high resolution remote sensing image [J]. Computer Engineering and Applications, 2019, 55(7): 207-213. [苏健民, 杨岚心, 景维鹏. 基于U-Net的高分辨率遥感图像语义分割方法[J]. 计算机工程与应用, 2019, 55(7): 207-213.]
- [18] Xu Huimin. Research on high resolution remote sensing image classification method based on deep learning U-Net model [D]. Chengdu: Southwest Jiaotong University. [许慧敏. 基于深度学习U-Net模型的高分辨率遥感影像分类方法研究[D]. 成都: 西南交通大学, 2018.]
- [19] Chaurasia A, Culurciello E. LinkNet: Exploiting encoder representations for efficient semantic segmentation [C] // 2017 IEEE Visual Communications and Image Processing (VCIP), 2017. DOI: 10.1109/VCIP.2017.8305148.
- [20] Li L, Wang C, Zhang H, *et al.* Residual unet for urban building change detection with Sentinel-1 SAR data [J]. 2019 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2019), 2019: 1498-1501. DOI: 10.1109/IGARSS.2019.8898146.
- [21] Sergey I, Christian S. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C] // International Conference on Machine Learning. PMLR, 2015: 448-456. DOI: 10.5555/3045118.3045167.
- [22] Wu G M, Shao X W, Guo Z L, *et al.* Automatic building segmentation of aerial imagery using multi-constraint fully convolutional networks [J]. Remote Sensing, 2018, 10: 407. DOI: 10.3390/rs10030407.
- [23] Chen L C, Papandreou G, Kokkinos I, *et al.* DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848. DOI: 10.1109/TPAMI.2017.2699184.
- [24] Bittner K, Cui S, Reinartz P. Building extraction from remote sensing data using fully convolutional networks [J]. ISPRS Hannover Workshop: Hrigr 17-Cmrt 17-Isa 17-Eurocow 17, 2017, 42-1 (W1): 481-486. DOI: 10.5194/isprs-archives-XLII-1-W1-481-2017.
- [25] Everingham Mark, Gool Luc Van, Williams Christopher K I, *et al.* The pascal Visual Object Classes (VOC) challenge [J]. 2010, 8(2): 303-338. DOI: 10.1007/s11263-009-0275-4.
- [26] Polak M, Zhang H, Pi M H. An evaluation metric for image segmentation of multiple objects [J]. Image and Vision Computing, 2009, 27(8): 1223-1227. DOI: 10.1016/j.imavis.2008.09.008.
- [27] Carletta J. Assessing agreement on classification tasks: The Kappa statistic [J]. Computational Linguistics, 1996, 22(2): 249-254. DOI: 10.5555/230386.230390.

Reclamation Detection and Recognition of High Resolution Satellite Remote Sensing Image based on Deep Learning

Yu Fengshi¹, Sui Yi¹, Wang Changying¹, Chu Jialan²

(1.School of Computer Science and Technology, Qingdao University, Qingdao 266071, China;

2.School of Data Science and Software Engineering, Qingdao University, Qingdao 266071, China)

Abstract: Based on high-resolution satellite remote sensing images, automatic and accurate extraction of land use status of reclamation is an important technical means to realize the intensive use of reclamation. In view of the complex features of high-resolution satellite remote sensing images, the traditional method of manually extracting features is difficult to meet the actual needs of business departments. A framework of reclamation detection and recognition based on deep learning is proposed. The framework uses the multi constrained variant structure of U-Net network, and to solve the problem of inconsistent classification caused by complex features of high-resolution remote sensing images, full connection conditional random field and image corrosion operation are introduced to post-processing the segmentation results. The high-resolution satellite remote sensing images of Tianjin Binhai New Area in 2016 and 2020 were used as data sources to verify. The experimental results show that the overall accuracy rate, F1 score, kappa coefficient and mIoU of reclamation are 96.73%, 92.87%, 90.28% and 86.82% respectively. On this basis, the dynamic change characteristics of land use in the reclamation area are analyzed and extracted, which provides effective technical support for the intensive use and management of reclamation.

Key words: Reclamation; Deep learning; Detection and identification; U-Net

致 谢

2022年6月30日,《遥感技术与应用》第八届编委会会议以线上线下结合的方式召开,新一届编委会委员近60人通过腾讯会议参加了会议,会议由第八届编委会主任吴季研究员和主编施建成研究员主持并顺利完成了第七届编委会和第八届编委会交接工作,会议肯定了在第七届全体编委的共同努力下,期刊的学术水平和影响力取得的长足进步和持续发展。在此,编辑部向第七届编委会全体编委致以诚挚的敬意和感谢! 特别感谢不再担任第八届编委的专家,感谢他们多年来对刊物的大力支持和无私奉献!

《遥感技术与应用》编辑部
2022年8月