

基于深度学习的 Sentinel-1 SAR 影像洪水分割研究

孙书腾¹, 梁乃安², 刘培^{2,3}, 吴振豪⁴, 张霖²

(1.河南理工大学 测绘与国土信息工程学院,河南 焦作 454000;2.海南省海洋与渔业科学院,海南 海口 570000;
3.海南热带海洋学院崖州湾创新研究院,海南 三亚 572000;4.海口万水测绘科技有限公司,海南 海口 570000)

摘要 精确、自动化的洪水信息提取对于洪涝灾害应急救援等工作至关重要。针对传统水体阈值法自动化程度和精度较低的问题,提出了一种全自动的高精度洪水分割方法。首先从 Sentinel-1 雷达影像中提取有益于突出水体信息的特征因子,并与原始雷达数据进行融合,然后分别构建 U-Net 网络和 HRNet 网络对 Sen1Flood11 标准数据进行训练并评估在测试集上的性能,最后将训练好的模型应用于真实洪水事件下的 Sentinel-1 影像。研究结果表明:HRNet 在独立测试数据集下的提取精度为 91%,在真实洪水事件中能够显示出较强的泛化能力和提供近实时的洪水测绘服务。

关键词 Sentinel-1; 洪水分割; 深度学习模型

中图分类号: P237

文献标志码: A

文章编号: 1672-4097(2022)06-0012-04

0 引言

全球变暖、海平面上升、城市化等都导致未来洪涝灾害发生概率增加^[1]。中国是世界上自然灾害最为严重的国家之一,根据应急管理部统计的“全国十大自然灾害”,近三年来洪涝的发生频次逐年递增,对社会经济系统和人类生命安全造成严重威胁。在这种背景下,可靠、准确、近实时的洪水淹没区制图对应应急响应和灾害监测评估变得至关重要。

遥感观测具有覆盖范围广、时效性强等技术优势,已被用于获取各种空间和时间尺度的洪水信息。光学传感器易受到云雨等天气影响,在恶劣条件下难以获取高质量影像。SAR (Synthetic Aperture Radar) 具有全天时、全天候的观测能力,有效弥补了光学影像的不足,更适用于恶劣天气下的洪水监测^[2]。常用阈值分割法检测 SAR 影像中的水体,然而最佳阈值通常需要人工干预调整,限制了其通用性与自动化。近年来,深度学习方法,特别是卷积神经网络在洪水灾害中的研究快速增长^[3]。

Zhang 考虑到多源卫星数据集的不同特点和洪泛区土地覆盖类型的复杂性,提出了带噪声标签学习的神经网络洪水检测框架,在受灾区显示出良好的性能,但多源数据的预处理比较耗时^[4]。Dong 利用多种网络模型对鄱阳湖进行洪水监测,结果表明

深度学习模型的性能优于传统方法,但实验中数据集由目视解译标注,数据质量难以保证^[5]。Drakonakis 使用一个双时态和多模态的卫星图像数据集,并针对该数据集设计了一种深度学习模型,能够利用不同传感器获取的不同时相的影像检测洪水,然而该数据集是未公开的^[6]。以上研究表明,深度学习在洪水监测方面发挥着巨大作用,但由于缺乏公开可用的、精确注释的数据集,近实时洪水提取的研究仍处于起步阶段。

本文以 Sentinel-1 影像为数据源,将 HRNet 模型应用于鄱阳湖的洪水检测。首先介绍了研究区概况与数据集,其次阐述了 U-Net 和 HRNet 的网络结构及训练策略,然后分别将模型在测试集中进行评估,最后将最优模型应用到洪水事件中。结果表明本文的方法具有较高的精度和较强的泛化能力,能够快速提取洪水范围并应用到应急响应工作中。

1 研究区与数据

1.1 研究区

鄱阳湖是中国最大的淡水湖,位于江西省北部,长江中下游以南,地理范围横跨东经 115°49′~116°46′,纵跨北纬 28°24′~29°46′(图 1)。2020 年 7 月,鄱阳湖流域遭遇极端强降雨,大量农田、房屋被淹,造成大范围的洪涝灾害。

项目来源: ① 国家自然科学基金(42071007); ② 海南热带海洋学院崖州湾创新研究院开放课题重点项目(2022CXKFKT03); ③ 海南省自然科学基金高层次人才项目(421RC1107); ④ 海南省海洋与渔业科学院省本级项目(KYL-2023-01)

第一作者简介: 孙书腾, 硕士研究生, 研究方向为遥感影像信息提取。

通讯作者简介: 刘培, 博士, 副研究员, 研究方向为资源环境遥感、数据挖掘与模式识别等。

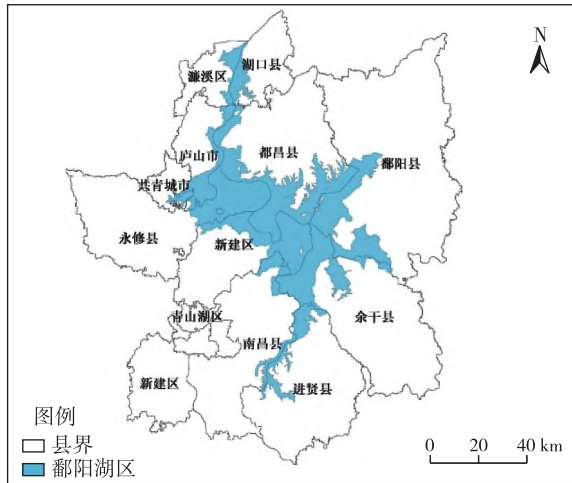


图 1 研究区地理位置

1.2 数据

1.2.1 哨兵数据

Sentinel-1 卫星星座由 Sentinel-1A 和 Sentinel-1B 两颗卫星组成,分别由欧空局于 2014 年 4 月和 2016 年 4 月发射升空,搭载 C 波段合成孔径雷达,两星协同观测,重访周期为 6 d。本研究使用的 Sentinel-1 影像从 GEE(Google Earth Engine)上下载,具体为 IW 模式下的 GRD 产品,包括 VV、VH 两种极化模式,分辨率为 10 m。

1.2.2 Sen1Floods11 数据集

Sen1Floods11 地表水数据集于 2020 年发布,目的用于深度学习算法在全球尺度范围内绘制洪水图^[7]。该数据集包括两个子数据集:永久水和洪水。手工标记的洪水数据集包括 446 幅 512 × 512 大小的 Sentinel-1 影像及对应的标签,分析人员通过参考 Sentinel-1 VH 波段、Sentinel-2 的假彩色影像及分类结果,去除不确定的区域,分类结果更加准确。

1.2.3 辅助数据

除上述数据外,本研究还使用了鄱阳湖矢量边界、Sentinel-1 影像相关指数产品、DEM 及地形因子、JRC 永久水等辅助数据。Sentinel-1 相关指数如表 1 所示,其中 VH、VV 分别表示 VH 偏振和 VV 偏振的后向散射系数。

表 1 基于 Sentinel-1 后向散射系数的 SAR 指数

指数	缩写	公式
极化比	VHrVV	$VHrVV = VH/VV$
归一化偏差极化指数	NDPI	$NDPI = (VV - VH)/(VV + VH)$
归一化 VH 指数	NVHI	$NVHI = VH/(VV + VH)$
归一化 VV 指数	NVVI	$NVVI = VV/(VV + VH)$
雷达植被指数	RVI	$RVI = (4 \times VH)/(VV + VH)$

1.2.4 训练、测试与验证样本集

本研究以 Sentinel-1 影像 VV、VH 波段为主要输入层,添加 SAR 指数、DEM 及地形因子、永久水等额外输入层,提高检测洪水的性能。

为验证模型的泛化能力,将数据集中所有与玻利维亚(Bolivia)洪水事件相关的影像用于独立的数据集,其余的数据按照 6:2:2 的比例随机划分,各个部分的样本大小如表 2 所示。

表 2 手工标记数据集划分

手工标记的数据集	样本大小
训练集	259
验证集	86
测试集	86
玻利维亚测试集	15

2 研究方法

2.1 网络模型

U-Net 模型是一个端到端的 U 形网络结构,由编码器和解码器两部分组成,通过跳跃连接将同层编码器下采样产生的特征图与解码器上采样的输出结果相连接^[8]。该网络结构相比于其他分割网络相对简单,并且在小样本数据集的情况下也可获得较好的分类效果。

高分辨率网络模型 HRNet 建立在并行架构的基础上,能够在保留高分辨率特征的同时提取低分辨率特征^[9]。HRNet 模型的主体分为 4 个阶段,第 1 阶段为高分辨率卷积,第 2、3、4 阶段由多分辨率块组成,每扩展一个阶段,增加一个高分辨率到低分辨率的卷积分支(图 2)。

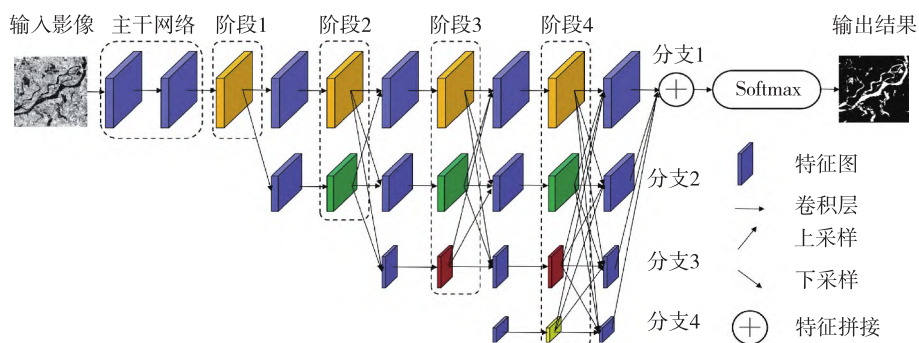


图 2 HRNet 网络结构

使用 Pytorch 框架来训练和验证模型,为提高模型的泛化能力,对训练集进行数据增强。对于整个训练过程,批处理大小设置为 16,在整个数据集上迭代 200 次,使用 Adam 优化器进行模型优化,初始学习率为 0.000 5,其他参数为默认。以往二元分割大多使用交叉熵作为损失函数,但洪水数据集中水体与非水体像元占比相差较大,训练过程需要考虑稳定性和类不平衡问题,因此将损失函数定义为 Dice 损失函数和交叉熵损失函数的加权,权重各为 0.5。

2.2 评价指标

选取交并比(IOU)、平均交并比(MIOU)、总体精度(OA)、漏分误差(Omission Error)、错分误差(Commission Error)等 5 个指标评估模型性能。各指标的公式定义如下:

$$IOU = \frac{TP}{TP + FP + FN} \quad (1)$$

$$MIOU = \frac{1}{2} \times \left[\frac{TP}{TP + FP + FN} + \frac{TN}{TN + FN + FP} \right] \quad (2)$$

$$OA = \frac{TP + TN}{TP + FP + TN + FN} \quad (3)$$

$$O_{MISSION} = \frac{FN}{TP + FN} \quad (4)$$

$$C_{OMMISSION} = \frac{FP}{TP + FP} \quad (5)$$

式中,TP 表示正确分类的水体像元,TN 表示正确分类的非水体像元,FP 表示非水体像元错误的分类为水体像元,FN 表示水体像元错误的分类为非水体像元。

3 试验与分析

3.1 测试集上提取结果与精度分析

在相同的实验环境下,分别对 U-Net 和 HRNet 模型进行训练。为对比两种模型的性能,在测试集中对训练好的模型进行评价,表 3 显示了各种指标的结果,最优值以粗体表示。

表 3 不同模型在测试集中的性能表现

方法	MIOU	IOU	OMI-SSION	COMMI-SSION	OA
U-Net	0.377	0.677 3	0.240 5	0.137 9	0.960 7
HRNet	0.420 9	0.682 8	0.230 2	0.142 1	0.962 5

从评价结果来看,U-Net 和 HRNet 的总体精度都在 0.96 以上,表明对水体与非水体像元的分割效果非常好。除错分误差外,HRNet 模型各项指标略优于 U-Net 模型,但两种模型训练时间差异较大,实际应用过程中可根据实际需求选择合适的模型。

为确保训练好的模型能够应用在研究区,使用玻利维亚数据集评估两种模型的性能,评价结果如

表 4 所示,最优结果用粗体表示。

表 4 不同模型在玻利维亚数据集的性能表现

方法	MIOU	IOU	OMI-SSION	COMMI-SSION	OA
U-Net	0.321 2	0.460 5	0.472 3	0.216 6	0.901 6
HRNet	0.350 9	0.515 5	0.418 4	0.180 4	0.912 8

从表 4 的各项评价指标来看,两种模型在玻利维亚数据集上的洪水识别精度整体上略低,但总体精度仍然在 90% 以上,具体原因为单次洪水事件中的影像被随机分到训练集、验证集、测试集中,导致不同集合的影像之间不可避免的具有空间自相关性。玻利维亚洪水事件的影像为独立的测试集,能真正反映出模型的泛化能力。结果也表明,利用 Sen1Flood11 数据集训练好的模型能够检测不同地域的水体,泛化能力是有效和稳健的。

3.2 受灾区水体识别结果

以 2020 年鄱阳湖洪水事件为例,对灾前 6 月 20 日和洪峰期 7 月 14 日的 Sentinel-1 影像进行洪水提取。研究区影像从 GEE 下载后,首先增加原始影像的输入通道并裁剪为 256×256 大小,然后将多幅影像切片输入到模型中进行推理,最后将模型推理结果进行镶嵌得到完整的研究区。

从研究区的提取结果来看(图 3),无论是灾前还

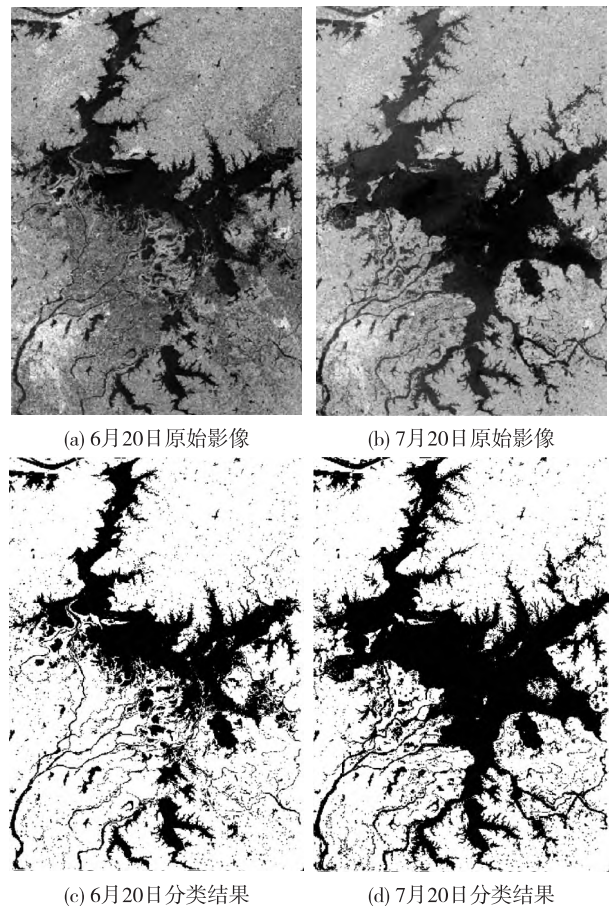


图 3 原始影像及分类结果

是洪峰期,HRNet 都能提取到鄱阳湖的水体轮廓。在细小河流方面,能够克服水体的不规则性,提取到清晰且完整的边界。尽管模型训练耗时,但将研究区影像输入到训练好的模型中,输出预测结果只需几分钟,在近实时检测水体方面显示出巨大的潜力。

4 结 语

本文提出了一种基于深度学习的 Sentinel-1 影像洪水分割方法,使用 Sen1Floods11 数据集对比了 HRNet 和 U-Net 网络的分割性能,并将最优模型 HRNet 应用于鄱阳湖的洪水检测中。实验结果表明,HRNet 在独立测试集上的精度为 91%,能够完整的提取水域轮廓,具有较强的泛化能力。

在后续研究中可以进行以下方面的工作:① 对添加的多个额外输入通道进行消融实验,研究多个输入通道是否都能提高模型检测洪水的性能;② 本文只对两幅影像的洪水范围进行提取,后续可应用多幅影像,对洪水的时空演变情况进行分析;③ 将洪水淹没范围与土地覆盖图进行叠加分析,对不同地物的受灾情况进行统计。

参考文献

- [1] KULP S A, STRAUSS B H. New Elevation Data Triple Estimates of Global Vulnerability to Sea-Level Rise and Coastal Flooding[J]. Nature Communications, 2019, 10(1): 1-12.
- [2] 郭山川,杜培军,蒙亚平,等.时序 Sentinel-1A 数据支持的长江中下游汛情动态监测[J].遥感学报, 2021, 25(10): 2127-2141.
- [3] BAI Y, GAO C, SINGH S, et al. A Framework of Rapid Regional Tsunami Damage Recognition from Post-Event TerraSAR-X Imagery Using Deep Neural Networks[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 15(1): 43-47.
- [4] ZHANG L, XIA J. Flood Detection Using Multiple Chinese Satellite Datasets during 2020 China Summer Floods[J]. Remote Sensing, 2021, 14(1): 51.
- [5] DONG Z, WANG G, AMANKWAH S O Y, et al. Monitoring the Summer Flooding in the Poyang Lake Area of China in 2020 Based on Sentinel-1 Data and Multiple Convolutional Neural Networks[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 102: 102400.
- [6] DRAGONAKIS G I, TSAGKATAKIS G, FO-TIADOU K, et al. OmbriaNet—Supervised Flood Mapping via Convolutional Neural Networks Using Multitemporal Sentinel-1 and Sentinel-2 Data Fusion[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 2341-2356.
- [7] BONAFILIA D, TELLMAN B, ANDERSON T, et al. Sen1Floods11: A Georeferenced Dataset to Train and Test Deep Learning Flood Algorithms for Sentinel-1[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. 2020: 210-211.
- [8] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional Networks for Biomedical Image Segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2015: 234-241.
- [9] SUN K, ZHAO Y, JIANG B, et al. High-Resolution Representations for Labeling Pixels and Regions[J]. ArXiv Preprint ArXiv, 2019:1904.04514.

Flood Segmentation of Sentinel-1 SAR Images Based on Deep Learning

SUN Shu-teng¹, LIANG Nai-an², LIU Pei^{2,3}, WU Zhen-hao⁴, ZHANG Lin²

(1. School of Surveying and Land Information Engineering, Henan Polytechnic University, Jiaozuo Henan 454000, China; 2. Hainan Academy of Ocean and Fisheries Sciences, Haikou Hainan 570000, China; 3. Yazhou Bay Innovation Institute, Hainan Tropical Ocean University, Sanya Hainan 572000, China; 4. Haikou Wanshui Surveying and Mapping Technology Co. Ltd., Haikou Hainan 570000, China)

Abstract Accurate and automated flood information extraction is essential for flood disasters emergency and relevant task. In this research, a high precision and automatically flood segmentation method is proposed to overcome the insufficiency of traditional threshold method. First, features which are beneficial to highlight water body information are extracted from Sentinel-1 radar images and are fused with the original radar data. Then, deep learning models such as U-Net network and HRNet are constructed, and Sen1Flood11 benchmark dataset are training and evaluated. Finally, the trained model is applied to Sentinel-1 images under real flood events. The results shown that extraction accuracy of HRNet deep learning model under independent test dataset is 91%, which also indicate strong generalization ability and provide near-real-time flood mapping services in real flood events.

Key words Sentinel-1; flood segmentation; deep learning model