

DOI:10.3969/j.issn.1003-5060.2026.07.017

基于改进 SwinU-Net 遥感影像 洪涝灾害信息提取与变化分析

袁啸宇¹, 李振轩¹, 韩久春², 杜海峰², 朱勇超¹, 张玉明²

(1. 合肥工业大学 土木与水利工程学院, 安徽 合肥 230009; 2. 安徽建工交通航务集团有限公司, 安徽 合肥 230011)

摘 要:利用遥感技术对影像进行信息提取是检测地表信息变化的一种重要手段,在城市发生洪涝灾害时的监测及灾后评估方面发挥着重要作用。在高分辨率遥感影像地表信息提取过程中,针对基础 SwinU-Net 网络精度不够高且出现地物边缘提取不清晰、小型地物提取不完整等问题,文章提出一种基于改进 SwinU-Net 网络的地表信息提取方法,并在 2021 年 7 月河南暴雨洪涝灾害遥感影像信息提取实验中得到验证。结果表明,该方法优于基础 SwinU-Net 提取方法及其他深度学习方法,能进一步提升分类精度,可有效完成洪涝灾害信息提取。

关键词:洪涝灾害;信息提取;深度学习;SwinU-Net 网络

中图分类号:P237

文献标志码:A

文章编号:1003-5060(2026)07-0976-07

Flood disaster information extraction and change analysis of remote sensing images based on improved SwinU-Net

YUAN Xiaoyu¹, LI Zhenxuan¹, HAN Jiuchun², DU Haifeng², ZHU Yongchao¹, ZHANG Yuming²

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China; 2. Anhui Construction Engineering Traffic and Shipping Group Co., Ltd., Hefei 230011, China)

Abstract: The extraction of information from images using remote sensing technology is an important means of detecting changes in surface information, and it plays a significant role in monitoring and post-disaster assessment of urban flood disasters. In the process of extracting surface information from high-resolution remote sensing images, there are issues with the baseline SwinU-Net network such as insufficient accuracy, unclear extraction of object edges, and incomplete extraction of small objects. To address these problems, a surface information extraction method based on an improved SwinU-Net network is proposed, and it was validated through experiments on remote sensing image information extraction during the heavy rain and flood disaster in Henan Province, China in July 2021. The experimental results demonstrate that this method outperforms the baseline SwinU-Net extraction method as well as several other deep learning methods, thereby improving the classification accuracy and effectively achieving flood disaster information extraction.

Key words: flood disaster; information extraction; deep learning; SwinU-Net

洪涝灾害在我国发生频繁,如何有效监测地表覆盖动态变化是降低洪涝灾害影响的关键^[1]。

目前利用遥感卫星影像获取地表覆盖变化信息已经成为监测地表覆盖动态变化的有效手段,同时

收稿日期:2023-10-31;修回日期:2023-11-28

基金项目:安徽省自然科学基金资助项目(2208085QD105)

作者简介:袁啸宇(1997—),男,安徽合肥人,合肥工业大学硕士生;

李振轩(1991—),男,山东汶上人,博士,合肥工业大学讲师,通信作者,E-mail:zxli2019@hfut.edu.cn.

也广泛应用于洪涝灾害监测^[2]。目前,洪涝遥感监测的关键技术在于对水体的提取。文献[3]基于合成孔径雷达(synthetic aperture radar, SAR)卫星影像所具有的全天时、全天候、穿透力强、成像面积大的特点,以 SAR 影像为数据源,通过阈值法进一步提高水体提取精度;文献[4]使用一种多模态序列遥感影像方法有效提升了洪水期 SAR 卫星影像灾害信息提取的精度;文献[5]针对高光谱遥感影像分类过程中面临的实际问题,把支持向量机(support vector machine, SVM)算法应用于高光谱遥感影像的分类中。但经典的 SVM 算法通常用于图像的二分类,在解决实际应用中遥感影像多分类问题时效果并不理想^[6-8]。近年来,深度学习方法兴起,并成功应用到遥感影像的信息提取与监测领域^[9]。

目前,主流深度学习提取方法有卷积神经网络(convolutional neural networks, CNN)^[10]、UNet^[11]、ResUNet^[12]等,UNet、SwinU-Net 网络已经在医学图像分割领域表现出优异的性能,但在地物类别复杂的遥感影像地表信息提取任务中往往出现精度不够高、地物边缘提取模糊等问题,难以达到优异的效果^[13-15]。本文提出一种基于改进 SwinU-Net 网络的遥感影像洪涝灾害信息提取方法,此模型保留了基础 SwinU-Net 网络体系结构,在原网络编码器的 Swin Transformer 结构中加入一种特征压缩模块(finite context model, FCM)^[16],用于提高模型运算效率。在解码器部分,用一种跨块注意力机制模块(cross attention block, CAB)^[17]取代原网络结构的 Swin Transformer 模块,以此构建新的网络体系。

为了验证本文提出的基于改进 SwinU-Net 网络的遥感影像洪涝灾害信息提取方法的有效性,本文以 2021 年 7 月河南省中北部发生的洪涝灾害为研究对象,选取时间为 2021 年 7 月高分三号 3 期融合影像作为数据源,提取洪涝灾害发生前后地表覆盖变化信息。

1 方 法

1.1 SwinU-Net 网络

SwinU-Net 整体框架与 UNet 结构类似,是一种基于 Swin Transformer 的语义分割网络,结合了 Swin Transformer 的高效性和 UNet 的分割能力。

SwinU-Net 由编码器和解码器两部分组成。编码器部分采用了 Swin Transformer 的结构,其

中包含多个 Swin Transformer 模块,每个块由若干个 Swin Transformer 层组成。解码器部分采用了 UNet 的结构,其中包含多个上采样模块和卷积模块,用于将编码器的特征图还原为与原图相同大小的分割结果。编码器部分首先对输入图像进行多次下采样,得到一系列不同分辨率的特征图。这些特征图经过 Swin Transformer 模块处理后,得到了高层次的语义信息。解码器部分则将这些特征图进行上采样和合并,得到与原图相同大小的分割结果。上采样模块采用了反卷积操作或上采样+卷积的方式,用于将特征图的分辨率恢复为原始大小。而卷积模块则用于融合不同分辨率的特征图,以获得更准确的分割结果。

SwinU-Net 优势在于采用 Swin Transformer 的注意力机制能够自适应地对不同位置的特征进行加权,提高了分割精度。但 Transformer 在前期对特征图进行下采样和展平过程中,容易导致大量细节和结构信息的丢失,不利于物体密集、小尺度的遥感图像的语义分割;另外, Svin Transformer 结构在上采样和合并过程中加入偏移的基于窗口的多头自注意(spatial-wise multi-head self-attention, SW-MSA)模块操作虽然增大了感受野,但当图像像素很大时,计算量会呈指数增长。且 Swin Transformer 中仅仅是在局部以及相邻斑块之间进行交互,捕获全局信息能力较差,因此将 SwinU-Net 网络运用在高分辨率遥感影像的地物信息提取时,难以取得与计算机视觉任务中同等优异的性能。

1.2 改进的 SwinU-Net 网络

针对基础 SwinU-Net 网络提取地表信息时存在的问题,本文在原 SwinU-Net 基础上提出改进。改进的 SwinU-Net 网络总体结构与基础 SwinU-Net 网络结构类似,由编码器、跳跃连接和解码器 3 部分组成,网络结构如图 1 所示。

由于 Transformer 在前期对特征图进行下采样和展平过程中容易丢失大量细节信息和结构信息,在改进的网络结构编码器的 Swin Transformer 结构中加入 FCM 模块,FCM 将输入的高维特征图转换为低维表示,同时尽可能保留重要的特征信息。通过此操作,可以帮助模型更好地理解 and 表示输入特征图,有助于提高模型的表达能力和泛化能力。在解码器中,为解决 Swin Transformer 模块在上采样和合并过程中计算量过大且捕获全局信息能力较差的问题,引入 CAB 模块,CAB 将一个特征图中的每个位置与另一个

特征图中的所有位置进行交互,实现特征的跨通道的关联。CAB 模块能够捕捉不同特征图之间的关联信息,对于需要整合不同层级或分支的特征表示的任务非常有用,可以提高模型对于不同

尺度或语义的特征的理解能力。通过引入跨注意力机制模块不仅可以有效进行全局信息交互,同时也可以避免随着输入分辨率的增加而导致计算量的增加。




图 1 改进的 SwinU-Net 网络结构

1.3 FCM 模块

目前,FCM 在图像识别、目标检测、语义分割等计算机视觉任务中得到广泛应用,其结构图如图 2 所示。FCM 首先接收一个由之前卷积层或其他特征提取模块生成的高维特征图作为输入特征图;然后使用降维操作来减小特征图的维度,通过卷积层的下采样、池化操作或步幅调整等以减少计算和存储成本,通过调整卷积核大小、步幅和填充方式来减小特征图的空间尺寸;接着 FCM 进行特征选择和重组,在降维过程中,FCM 选择通过引入注意力机制、自适应权重或其他特征选择方式来保留最重要的特征或对特征进行组合和重组,以此在低维表示中保留最具代表性和有用的特征;最后,FCM 通过输出一个经过压缩的低维特征得到一个尺寸较小的特征图,可被送入后续的网络层进行分类、检测或其他任务处理。

FCM 减少了特征图的维度,使得整个模型的前向传播时间相应减少,提高了模型的效率。此外,FCM 通过保留重要的特征信息,可以帮助模型更好地理解 and 表示输入数据。有助于提高模型的表达能力和泛化能力,可有效防止 Transform-

er 在前期对特征图进行下采样和展平过程中导致细节信息和结构信息的丢失。




图 2 FCM 模块结构图

1.4 CAB 模块

CAB 是一种主要用于捕捉不同特征图之间的关联信息的模块,包括 MLP(multi-layer perceptron)和 LN(layer normalization)主要基础组件,其结构如图 3 所示。传统的 MSA 模块对于特征图中的每个像素在自注意计算过程中需要与所有像素计算,Swi Transformer 模块中引入 W-MSA 模块和 SW-MSA 模块,首先将特征图按照 2×2 大小划分成多个窗口,然后单独对每个窗

口内部进行自注意计算。

每个像素点都需要一个通道来表示其特征,但当图像像素很大时,计算量会呈指数增长。计算量表达式为:

$$\Omega_{\text{MSA}} = 4hwC^2 + 2(hw)^2C \quad (1)$$

$$\Omega_{\text{W-MSA}} = 4hwC^2 + 2m^2hwC \quad (2)$$

其中: h 、 w 分别为特征图像的高度和宽度; C 为划分后 Patch 特征维度; m 为一个窗口里 Patch 数量。

CAB 模块受 CNN 中的局部卷积方法的启发,引入 Inner-Patch Self-Attention(IPSA)模块,把每个 Patch 当作一个注意力范围,在每个 Patch 中进行每个像素块的自注意计算。IPSA 模块可有效保证每个 Patch 内部像素之间的相互关系被捕获。同时为了确保整个画面的信息交换,引入 Cross-Patch Self-Attention(CPSA)模块,将每个通道特征图分离,每个通道被划分为 $H/N, W/N$ 个 Patch,然后利用 Self-Attention 获得整个特征图中的全局信息。IPSA 模块和 CPSA 模块计算量表达式为:

$$\Omega_{\text{IPSA}} = 4hwC^2 + 2m^2hwC \quad (3)$$

$$\Omega_{\text{CPSA}} = 4m^2wC + 2(hw/m)^2C \quad (4)$$

因此在上采样和合并过程中用 CAB 模块取代原 Swin Transformer 模块,可以有效提高模型对于不同尺度或语义的特征的理解能力,且可以有效解决计算量过大、捕获全局信息能力较差等问题。




图 3 CAB 模块结构

2 实验数据与算法评价

2.1 研究区域概况与实验数据

本研究以 2021 年 7 月河南省洪涝灾害过程为背景,选取受灾较严重的郑州市辖区,包括金水区、中原区、二七区以及惠济区作为研究区域。本文实验数据采用 GF-3 卫星 L2 级产品,成像模式为 FSII 的 HV 极化 SAR 影像。

选取郑州市暴雨前的 7 月 17 日影像、暴雨过程中的 7 月 20 日影像和 7 月 25 日灾后共 3 期 SAR 影像数据,空间分辨率为 5 m。将选取的区域影像统一裁剪成尺寸为 256×256 的影像,得到初步样本数据。

为进一步提高样本质量,使训练出来的模型效果更好,本研究对样本数据进行数据扩充,通过垂直翻转、水平翻转、随机旋转 90° 和随机剪裁操作,得到约 10 000 个样本数据。划分为训练集(6 936 幅)、验证集(2 037 幅)和测试集(1 027 幅) 3 个部分。

2.2 评价指标

采用总体分类精度 O_A 、查全率 R_e 、 K_a 系数作为地表信息提取评估标准。 O_A 为模型在所有样本上正确分类的比例; R_e 为标签中某类别被预测正确的概率,即正确预测的像元占研究区域真值像元的比例; K_a 为度量一致性的指标系数,检验模型预测结果与实际分类结果是否一致。各评估标准公式为:

$$O_A = \frac{T_P}{T_P + F_N + F_P + T_N} \quad (5)$$

$$R_e = \frac{T_P}{T_P + F_N} \quad (6)$$

$$K_a = \frac{P_0 - P_e}{1 - P_e} \quad (7)$$

其中: T_P 为真正例的数量,即模型将正例正确分类为正例的样本数; T_N 为真反例的数量,即模型将反例正确分类为反例的样本数; F_P 为假正例的数量,即模型将反例错误分类为正例的样本数; F_N 为假反例的数量,即模型将正例错误分类为反例的样本数; P_0 为总体分类精度; P_e 为各类别对应的标签值与预测值的乘积之和除以样本总和的平方得到的结果。

2.3 硬件配置和参数设置

试验模型的训练和测试均在 PyTorch 开发框架下进行,硬件配置采用 NVIDIA GeForce RTX4060。经过多次迭代训练和对比试验,并对验证数据集进行损失和精度的计算,确定了该网络的最优模型参数:网络优化器采用 Adam 优化器;学习率设为 0.000 1;epochs 值设为 50;batch size 值设为 8。

基于改进的 SwinU-Net 模型的精度和损失值变化情况如图 4 所示。由图 4 可知,在模型训练过程中,随着迭代次数的增加,准确率逐步上升,约在第 80 次后准确率趋于稳定,维持在 0.91

左右;损失值在不断下降,最终稳定在 0.085 左右。




图 4 改进的 SwinU-Net 精度和损失值变化

为探究本文提出的改进的 SwinU-Net 方法在地物信息提取方面的优势,把本文方法与传统机器学习方法 SVM 以及主流的深度学习方法 UNet、SwinU-Net 方法做对比试验。其中,SVM 算法在 ENVI 中完成,并通过分类结果对比确定 SVM 的最优参数设置;深度学习方法对比试验中,为满足不同模型在最优参数的条件下得到的试验结果,UNet、SwinU-Net 和本文方法采用相同的初始学习率和优化器,试验中其模型参数均与改进的 SwinU-Net 模型参数一致,3 种深度学

习算法测试精度对比结果如图 5 所示。




图 5 3 种深度学习算法精度对比

由图 5 可知,在相同的训练和测试环境下,UNet、SwinU-Net 的最终精度为 0.88 左右,改进的 SwinU-Net 方法能够取得更好的测试精度,大约比 UNet、SwinU-Net 方法高出 0.03。

3 结果与分析

3.1 可视化结果分析

为验证本文方法在遥感影像洪涝灾害信息提取与监测方面的有效性,选用 SVM 方法以及主流深度学习提取方法 UNet、SwinU-Net 与本文方法对比,每次实验随机选取同样规模的训练样本进行训练,且几种分类方法训练环境保持相同。由于深度学习方法训练时间较长,本次结果为 5 次随机实验的平均结果。各方法的可视化分类结果如图 6 所示。




图 6 各类提取方法地表信息提取结果对比

由图 6 可知,SVM 方法的提取效果不理想,提取结果中存在大量噪声,细碎斑点较多,且对于一些非水体的地物划分上出现了较为严重的错分。UNet 和 SwinU-Net 方法总体可以较好实现地表信息的提取,有效地减少了影像地表信息提

取的噪声,使地表信息提取结果更加平滑,但在一些细小水体和道路的提取上仍存在缺陷。图 6 黑色方框内为 3 种深度学习方法和本文方法提取效果差异较大的部分。

在区域 a 中,UNet 和 SwinU-Net 对道路提

取不完整,且二者在绿地边缘的部分水体提取效果不明显,对于下方方框内的细小水体提取不够完全。区域 b 和 c 中,UNet 和 SwinU-Net 方法误将部分绿地划分为水体,在道路和滩涂分界处区分效果不佳。而本文方法从提取效果来看能较好地识别地物间的连接部分,且对于一些道路和建筑的边缘以及细小水体的提取上把控得更好。

3.2 精度比较与分析

利用 O_A 、 R_e 和 K_a 作为评估标准对地表信息提取结果进行量化分析,评价结果见表 1 所列。由表 1 可知,SVM 算法对各类地物的分类以及总体提取精度皆最低,提取效果不太理想。与 SVM 算法相比,深度学习方法 UNet、SwinU-Net 的各个指标值远优于 SVM 算法,在大部分地物的提取上解决了 SVM 存在的错分问题,但部分细微地物被忽略或是漏检,地物间边缘部分提取效果不佳。本文方法相较于 SVM 算法在总体精度上提高了 20% 左右,相较于 UNet 和 SwinU-Net 在总体准确率、 R_e 值及 K_a 值上均有所提高,综合表 1 可知,本文方法所得到结果为定量评价最优结果。由 3.1 节分析可知,表现在对地物边缘及细小水体提取方面的改进,对细小水体信息提取更准确,且对其他地物的边缘细节处理更加完善。

表 1 地表信息提取识别精度及定量评价结果比较 %

指标		提取方法			
		UNet	SwinU-Net	SVM	本文方法
识别精度	建筑	94.77	95.18	83.75	96.12
	植被	79.34	78.57	63.21	79.78
	道路	82.55	80.23	68.97	84.21
	滩涂	87.43	87.01	72.39	86.54
	水体	92.18	91.67	85.66	94.03
	O_A	91.46	90.28	81.29	93.07
	R_e	89.32	87.60	78.54	89.72
	K_a	92.20	91.98	80.32	93.39

结合图 6 及表 1 可知:本文提出的基于改进 SwinU-Net 的遥感影像洪涝灾害信息提取方法无论在目视提取效果上还是精度对比方面均优于 UNet 方法和基础 SwinU-Net 方法,在原方法具有缺陷的地方均得到了改进,精度上也得到了进一步提升。由此,进一步利用本文方法对降雨前后郑州市区域影像进行地表信息总提取,得到提取结果如图 7 所示。

进一步对郑州市区域影像提取后的结果统计各个地表类别的像元面积数,得到各地物面积变化结果如图 8 所示。

由图 8 可知,从 7 月 17 日到 25 日郑州市地表信息提取结果中,水体变化最为明显,水体面积由 196.32 km² 扩大到 253.43 km²;植被面积在不断缩减,由 442.14 km² 减少至 423.77 km²。结合图 6 可视化结果可知,淹没区域主要集中在北部和东南部。其中,金水区、中原区以及惠济区南部受洪灾影响最为严重,二七区和惠济区北部基本未受到洪水影响。




图 7 2021 年郑州市辖区 3 个时期地表信息总提取




图 8 灾害前、后各地表类别面积变化

综上,通过本文方法提取到的郑州市辖区水体淹没范围以及水位变化等信息,可以帮助监测人员及时了解到郑州市洪涝灾害的发展态势,提前作出预警、制定应对措施。通过对自动提取到的郑州受灾区域土地利用类型、建筑物覆盖情况及植被状况等信息,并结合相关经济数据和统计模型,可对洪涝灾害造成的经济损失进行估计,为政府和救援机构提供决策参考,帮助其更好地应对洪涝灾害并制定相应的防灾减灾措施。

4 结 论

1) 以郑州市 2021 年 7 月 3 期 GF-3 影像作为实验数据集,使用改进的 SwinU-Net 提取方法对遥感影像中的各类地物进行精确提取。将其与 SVM、UNet 和基础 SwinU-Net 这 3 种方法进行对比分析可知,SVM 分类算法在高分辨率遥感影像地表中提取存在漏检现象,且噪声较多,分类精度较低。

2) 在利用本文提出的改进的 SwinU-Net 方法和深度学习方法 UNet、SwinU-Net 对高分辨率遥感影像地物分类提取的结果中,总体准确率均超过 90%,但相比之下改进的 SwinU-Net 方法在分类效果上更优,对细小水体的提取效果更清晰、误检的地物大大减少。通过对以上 3 种分类方法所得到的结果进行定性和定量分析,在有限的迭代次数及试验区域内,基于改进的 SwinU-Net 网络对遥感影像洪涝灾害信息提取效果更好、精度更高,具有一定的可行性和真实有效性。

但目前基于改进的 SwinU-Net 网络提取方法仍存在一些不足,一方面表现在模型参数量较大,运行速度偏慢,导致模型训练时间偏长,另外,本文方法通常需要大量标记的训练数据才能达到最佳性能,如果缺乏或存在偏差的训练数据就可能限制模型的泛化能力,影响其准确性。后续研究将在网络结构调整、数据增强、损失函数优化等方面进行探索和改进。

[参 考 文 献]

- [1] 高伟,沈秋,李梦璠,等. 基于多源遥感数据的洪涝淹没范围时序监测分析[J]. 测绘与空间地理信息, 2018, 41(7): 8-10, 14.
- [2] Hong S, Jang H, Kim N, et al. Water area extraction using RADARSAT SAR imagery combined with landsat imagery and terrain information[J]. Sensors, 2015, 15(3): 52-67.
- [3] 王敬明,王世新,王福涛,等. 基于 Sentinel-1 SAR 数据洪水淹没提取方法研究[J]. 灾害学, 2021, 36(4): 214-220.
- [4] 眭海刚,赵博飞,徐川,等. 多模态序列遥感影像的洪涝灾害应急信息快速提取[J]. 武汉大学学报(信息科学版), 2021, 46(10): 1441-1449.
- [5] 丁胜锋. 基于 SVM 的高光谱遥感影像集成分类方法研究[D]. 葫芦岛: 辽宁工程技术大学, 2018: 14-20.
- [6] Zhao H, Wang C, Chen J, et al. Waterbody information extraction from remote-sensing images after disasters based on spectral information and characteristic knowledge[J]. International Journal of Remote Sensing, 2017, 38(5): 134-142.
- [7] 王景旭,邱士可,王正,等. 基于 GF-3 号遥感影像水体信息提取的郑州市洪涝灾害监测[J]. 河南科学, 2021, 39(10): 1701-1706.
- [8] 孔凡明,蒋卫国,李京,等. 基于 MODIS 的 2011 年泰国洪涝受灾信息提取与分析[J]. 灾害学, 2013, 28(2): 95-99.
- [9] 宗达. 深度学习在洪涝灾害评估方面的关键技术研究[D]. 青岛: 青岛科技大学, 2021: 23-53.
- [10] 王飞,王奔宇,韦靖峰,等. 基于 CNN 智能算法的路面损坏轻量化识别系统应用研究[J]. 公路, 2023, 68(1): 391-395.
- [11] 麻连伟,宁卫远,焦利伟,等. 基于 U-Net 卷积神经网络的遥感影像变化检测方法研究[J]. 能源与环保, 2022, 44(11): 102-106.
- [12] 胡煦航,程小龙,朱滨,等. 基于改进 ResUnet 的高分辨率遥感影像道路信息提取[J]. 遥感信息, 2022, 37(4): 87-93.
- [13] Sheng Y, Gong P, Xiao Q. Quantitative dynamic flood monitoring with NOAA AVHRR[J]. International Journal of Remote Sensing, 2001, 22(9): 1709-1724.
- [14] 李戈伟. 基于遥感和 GIS 的洪灾监测与评估方法研究[D]. 北京: 中国科学院研究生院(遥感应用研究所), 2002: 6-44.
- [15] Xu S, He X P, Cao X L, et al. Damaged building detection with improved swin-unet model[J]. Wireless Communications and Mobile Computing, 2022, 34(3): 23-33.
- [16] Cai W J, Wang Y F, Ma J H, et al. Effective crossfeatures by global attention mechanism and neural network for Ad click prediction[J]. Tsinghua Science and Technology, 2022, 27(1): 186-195.
- [17] 王美,苏雪松,刘佳,等. 时频域多尺度交叉注意力融合的时间序列分类方法[J]. 计算机应用, 2024, 44(6): 1842-1847.

(责任编辑 吴 亮)