

中文引用格式:钟兴润,田晨斌,李新宏,等. 基于改进 U-Net 的城市洪涝灾害图像识别模型[J]. 中国安全科学学报,2025,35(10): 190–197.

英文引用格式:ZHONG Xingrun, TIAN Chenbin, LI Xinhong, et al. Improved U-Net-based model for urban flood disaster image recognition [J]. China Safety Science Journal,2025,35(10):190–197.

基于改进 U-Net 的城市洪涝灾害 图像识别模型*

钟兴润¹讲师,田晨斌^{**1},李新宏¹教授,孟晓静^{1,2}教授,杨文欣¹

(1 西安建筑科技大学 资源工程学院,陕西 西安 710055;

2 西安市工业职业危害评价与防治技术重点实验室,陕西 西安 710055)

中图分类号:X915.5

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2025.10.1312

资助项目:校企合作项目(XAJD-YF23N010)。

【摘要】 为解决洪涝灾害识别模型在城市复杂背景下区域分割不清和细节还原不足等问题,提升洪涝灾害图像识别准确性,提出一种基于残差网络和自注意力机制的改进 U-Net 语义分割模型——AttResU-Net 模型。该模型在经典 U-Net 网络架构基础上进行优化设计,采用深层残差网络作为编码器以增强特征表达能力,同时在解码器中引入注意力机制,以提高对关键洪涝区域的响应能力;构建完整的训练与测试流程,使用 FloodNet 多类别复杂环境数据集训练改进 AttResU-Net 模型,从定量指标和定性可视化效果 2 个维度来评估模型性能,并与现有主流模型进行对比分析。结果表明:AttResU-Net 模型在平均像素准确率(mPA)、像素准确率(PA)、平均精度(mPrecision)等指标上表现优异,其中,mPA 为 79.75%、PA 为 90.01%、mPrecision 为 81.78%;相比其他模型,AttResU-Net 模型在树木、水体、道路和建筑物等识别中表现出更高的分割准确率、全局像素精度和全局识别能力。

【关键词】 U-Net; 洪涝灾害; 图像识别; 图像分割; 注意力机制; 残差

Improved U-Net-based model for urban flood disaster image recognition

ZHONG Xingrun¹, TIAN Chenbin¹, LI Xinhong¹, MENG Xiaojing^{1,2}, YANG Wenxin¹

(1 School of Resource Engineering, Xi'an University of Architecture and Technology,

Xi'an Shaanxi, 710055, China; 2 Xi'an Key Laboratory of Industrial Occupational

Hazard Evaluation and Prevention Technology, Xi'an Shaanxi 710055, China)

Abstract: In order to address the challenges of inaccurate region segmentation and insufficient detail restoration in flood disaster recognition models within complex urban environments, AttResU-Net, an enhanced U-Net semantic segmentation model integrating residual networks and a self-attention mechanism was proposed. Building upon the classical U-Net architecture, the model employed a deep residual network as the encoder to strengthen feature representation. Simultaneously, self-attention mechanisms were

* 文章编号:1003-3033(2025)10-0190-08; 收稿日期:2025-04-10; 修稿日期:2025-07-11

** 通信作者:田晨斌(2000—),男,山西临汾人,硕士研究生,主要研究方向为安全检测与风险评估。E-mail:1214120004@qq.com。

incorporated into the decoder to enhance response capability on key flood-related regions. A comprehensive training and testing pipeline was established. The improved AttResU-Net was trained and evaluated on the FloodNet dataset, which contains diverse and complex urban environmental categories. Quantitative metrics and qualitative visual results demonstrate the model's superior performance, achieving a mean pixel accuracy (mPA) of 79.75%, pixel accuracy (PA) of 90.01%, and mean precision (mPrecision) of 81.78%. Comparative experiments against state-of-the-art models reveal that AttResU-Net attains significantly higher segmentation accuracy and global recognition capability, particularly for urban features such as trees, water bodies, roads, and buildings.

Keywords: U-Net; flood disaster; image recognition; image segmentation; self-attention mechanism; residual network

0 引言

由于全球气候变化,气候极端事件频发,各国面临的洪涝灾害风险显著增加,暴雨洪涝灾害损失占全球自然灾害损失约 40%^[1-2]。我国是暴雨洪涝灾害频发的地区之一,2023 年国家应急管理部发布的全国十大自然灾害中,暴雨洪涝灾害占据 30%。为有效应对洪涝灾害带来的挑战,提升应急响应能力,实现洪涝灾害区域的自动化智能识别成为一项重要任务。

随着城市化进程加快,城市洪涝灾害对城市基础设施、经济发展和人民生命财产安全已构成重大威胁^[3]。当前多数城市仍依赖人工观测或传统监测设备进行灾害评估,存在响应不及时、信息传输延迟及人力成本高等问题,尤其在洪涝高发季节容易引发次生灾害。自动化、智能化识别技术成为提高应急响应效率的关键。近年来,无人机遥感技术在洪涝灾害监测中得到广泛应用^[4]。早期的洪涝区识别方法主要包括光谱特征法^[5]和阈值分割法^[6],李昕悦等^[7]探讨了光谱特征法和阈值分割法在城市洪涝的水体的优缺点,发现这些传统方法在简单场景下表现良好,但在积水反光、建筑倒影等复杂背景或阴影干扰下识别精度较低,泛化能力不足。此外,这些方法大多依赖固定阈值和规则设定,难以适应多变的洪涝场景,尤其在不同光照、地物反射特性下易出现误判与漏判。因此,学者们逐渐开始应用深度学习技术,特别是语义分割模型,如 U 型网络 (U-Net)^[8]等深度学习网络在图像分类中取得显著成功。郭玮等^[9]为提高洪涝灾害应急救援辅助决策能力,快速提取洪水淹没范围,提出了一种基于深度学习的合成孔径雷达影像洪水淹没范围提取方法,与传统的自适应阈值方法相比,此方法具有更高的识别精度。LI Wenning 等^[10]提出的 SU-Net 模型

能够更准确地识别城市复杂背景下的水体区域,解决了传统方法因建筑阴影和道路干扰导致的误判问题,为城市水矢量制图提供依据。ZHAO Jie 等^[11]提出了一种基于城市意识的 U-Net (Urban-Aware U-Net) 模型,利用多时相 Sentinel-1 数据提高了大规模城市洪涝映射的精度和效果,解决了大范围城市洪涝淹没区精准提取的难题,克服了传统洪水监测方法在城市区域因雷达信号混叠导致的误判问题,在近实时城市洪水测绘方面具有较强潜力。KIM 等^[12]提出了一种结合深度学习和云计算平台的自动洪涝区域提取方法,展示了深度学习在洪涝监测中的巨大潜力,证明了全自动洪水监测系统的运行稳健性。

尽管已有研究在提升洪涝识别精度、适应复杂地形条件方面取得一定成效,但仍存在一些亟待解决的问题。FENG Wenqing 等^[13]通过增加 U-Net 的网络深度并结合超像素分割和条件随机场模型,提高了从超高分辨率遥感影像中提取水体的精度和细节恢复能力。然而,随着网络深度的增加,可能会出现梯度消失或梯度爆炸问题^[14],导致模型收敛困难,训练不稳定。此外,传统卷积神经网络在下采样过程中容易导致空间细节信息的丢失,使得解码器在恢复高分辨率特征时受限,造成对细小水体区域识别不完整、水体边缘模糊的现象。并且,如 Urban-Aware U-Net^[11]等模型虽在大规模城市中表现优秀,但往往依赖多源或多时相数据,难以在资源有限或应急场景中快速部署。

鉴于此,笔者将提出一种融合自注意力机制和残差 (Attention-Residual (AttRes)) 模块的改进洪涝灾害监测图像识别模型——AttResU-Net 模型,以期实现复杂背景下洪涝区域的准确识别,提高洪涝灾害监测与预防能力。

1 改进 U-Net 网络模型结构设计

1.1 残差网络 (ResNet)

残差网络 (Residual Network, ResNet^[14]) 是一种深度卷积神经网络架构,旨在解决深度神经网络训练中可能出现的梯度消失或爆炸问题。ResNet 引入了残差学习的概念,即通过引入跨越网络层的捷径连接来显著降低网络层数增加引起的性能减弱问题。这些捷径连接允许网络直接学习残差函数,找出目标映射与输入之间的差异,更有效地学习和优化复杂图像的不同特征表示。

ResNet 的核心创新在于残差块,每个残差块由 2 条路径组成:主路径和跳跃连接。主路径执行卷积操作;跳跃连接允许输入直接跳过一个或多个层,连接到更深层的网络部分,然后通过相加操作将跳跃连接的输出与主路径的输出相结合。这种设计使得网络能够更深层地学习特征,避免深层网络训练时可能出现的梯度消失或爆炸问题,提升大规模图像分类或其他计算机视觉任务执行的性能。文中选用 ResNet50 作为编码器,删除 ResNet50 的全局平均池化层和全连接层,保留卷积层和残差模块用于提取图像特征和连接解码器。

1.2 自注意力门控机制

自注意力门控机制^[15]是深度学习领域中的一种先进技术,旨在通过引入自注意力机制来增强模型对重要区域的动态关注能力。其基本思想是在特征提取过程中,自动分配不同特征的权重,从而突出关键特征并抑制无关特征,提升模型性能。

具体来说,注意力 U-Net 在每个解码器层中都添加了一个注意力子模块,以帮助模型更准确地学习如何区分前景和背景。该子模块利用注意力门控网络,自动地对前景和背景进行建模,并计算不同位置的像素权重,从而使模型能够更加聚焦关注区域,提高分割质量。注意力 U-Net 中的注意力子模块由 3 个部分组成:查询嵌入(解码器的特征向量)、键嵌入(编码器的特征向量)和值嵌入(加权后的编码器特征向量)。其中,查询嵌入和键嵌入通过卷积神经网络从解码器和编码器的特征图中计算得到;然后,通过对查询嵌入和键嵌入进行点积计算,得到权重矩阵,经 Softmax 归一化后与值嵌入相乘,得到加权后的编码器特征向量。

1.3 AttResU-Net 改进模型

U-Net 是一种广泛应用于图像分割任务的卷积

神经网络模型,具有对称的编码器-解码器结构。编码器通过逐层卷积和池化操作提取图像特征;解码器通过上采样和卷积操作逐步恢复图像的空间分辨率,同时融合编码器相应层的特征,以获取更精准的分割结果。

为改进 U-Net 模型存在的区域识别不完整、边缘模糊等问题,更好地识别洪涝区域,在 U-Net 模型基础上,编码器采用 ResNet50,利用其强大的特征提取能力处理深层次特征;解码器引入自注意力机制,借助其动态区域关注能力,提升模型对洪涝区域的识别能力,恢复和处理洪涝关键区域的细节。改进 AttResU-Net 模型在复杂背景下能更准确地分割洪涝区域,提高洪涝灾害识别的整体效果,其结构如图 1 所示。

具体而言,执行图像分割任务时,首先输入图像,在编码器部分,步骤(STAGE)0 通过卷积层、批量归一化层和激活函数提取初步特征,并进行下采样,为后续阶段打下基础。STAGE 1 使用多个残差块进一步处理特征图,提取图像的低层次特征,通过残差连接解决深层网络中的梯度消失问题。STAGE 2 和 STAGE 3 继续通过残差块和下采样操作,分别提取中层次和深层次特征,增强了特征表达的多样性和丰富性,使模型能够处理复杂场景。STAGE 4 通过瓶颈块提取最复杂和抽象的特征,为解码器部分提供丰富而高质量的信息。

在解码器部分,引入自注意力机制,计算特征图中每个像素点的重要性,通过查询、键和值等对特征图的重要信息动态加权,从而使模型更关注目标区域边界和细节。解码器通过上采样逐步恢复特征图的空间分辨率,并使用跳跃连接传递编码器相应阶段的特征图,以保留更多细节信息。在每个解码阶段,引入自注意力机制模块,通过动态加权来强调重要区域的特征,最终输出一个高分辨率的分割图像,更好地恢复和处理目标区域的边界和细节。

2 洪涝灾害图像识别模型与数据分析

2.1 洪涝灾害图像识别模型参数设置与训练

采用 FloodNet Dataset^[16]数据集,该数据集由无人机航拍采集的高分辨率图像构成,共 2 343 张图像,提供了包含建筑物、水体、道路等多类城市要素的语义标注信息,展示出地区综合环境的复杂性,可用于洪涝灾害场景分析,适用于城市洪涝灾害的监测。将该数据集按照 8 : 1 : 1 的比例分为训练集、




图 1 改进 AttResU-Net 模型结构原理

Fig. 1 Schematic diagram of the structure of the improved AttResU-Net model

验证集和测试集,每个集合内都包含原图以及相应的标签图;为提升模型训练效果,对原始图像进行尺寸缩放、随机增强与格式标准化等统一化处理,数据预处理流程及图像处理效果如图 2 所示。




图 2 数据预处理流程及图像处理效果

Fig. 2 Data pre-processing process and image processing effect demonstration

在 Win11 系统电脑上,采用 PyTorch 深度学习框架进行网络模型训练,训练前配置主要参数,训练参数设置为:图像输入大小设置为 $512 \times 512 \times 3$,批次划分为 4,迭代次数为 350 次,学习率设置为 0.000 1,并采用衰减学习率策略,衰减率为 10^{-6} ,优化器选择 Adam,使用交叉熵损失函数优化模型的性能。

模型在训练过程中,首先在训练集和验证集上使用交叉熵损失函数计算损失值,每迭代 10 次后,

使用测试集评估模型的性能。为防止过拟合,训练过程采用保留最佳参数性能的策略,追踪并记录在测试集上表现最佳的模型参数,保存并计算平均交并比 (Mean Intersection over Union, mIoU)、平均像素准确率 (Mean Pixel Accuracy, mPA) 和像素准确率 (Pixel Accuracy, PA)。为节省硬件资源、稳定训练过程、加快模型收敛速度,采用冻结训练策略,先固定模型的主干特征提取部分,只训练模型解码器;主干部分训练充分后解冻整个模型,进行端到端的微调。

2.2 评价指标

采用 mIoU、像素精确度 (Precision, P)、平均精度 (Mean Precision, mPrecision)、召回率 (Recall)、平均召回率 (Mean Recall, mRecall)、PA 和 mPA 等评估指标衡量语义分割模型的性能和准确度。mIoU、IoU 评估模型图像分割后结果与真实标签的整体、平均重叠程度;Precision、Recall 分别衡量精确度、敏感度;PA、mPA 反映整体、平均像素分类准确性。

2.3 洪涝灾害图像识别模型结果对比

为验证改进模型的有效性,将改进 AttResU-Net 与 TransUNet^[17]、Vgg-UNet^[18] 和 ResU-Net^[19] 和 AttVgg-Unet 进行对比分析,验证改进模型在洪涝灾害识别中的结构提取能力和区域分割性能。

2.3.1 图像识别模型结构提取能力

为验证改进后的 AttResU-Net 在洪涝灾害图像识别中的结构提取能力,在 FloodNet 数据集上进行试验。为展示模型的结构提取能力,从测试集中随机挑选了 3 张图像,并展示了其测试结果,如图 3 所示。




图 3 不同模型结构提取效果

Fig. 3 Demonstration of the extraction effect of different model structures

在 FloodNet 数据集的图像分割任务中,各种模型在不同方面的表现存在显著差异。

在建筑物分割方面,TransUNet 和 Vgg-UNet 能够识别建筑物的大致轮廓,但在边缘处理和细节上表现不足。相比之下,ResU-Net 和改进的 AttResU-Net 在建筑物区域的准确识别和边缘处理上表现较好,但细节部分仍有改进空间。特别是 AttResU-Net 在细节和边缘处理上表现出色,建筑物轮廓更清晰,误分割现象较少。

在道路分割方面,所有模型在大致识别道路方面表现较好,但在处理复杂路况(如交叉口)时,TransUNet 和 Vgg-UNet 易出现断裂和误分割现象,而 ResU-Net 及 AttResU-Net 的连续性处理较为优秀,能够更好地处理复杂路况。

在水体分割方面,TransUNet 和 Vgg-UNet 能够分割出大部分水体区域,但在细节处理和边缘模糊区域存在不足。相比之下,ResU-Net 和 AttResU-Net 在水体区域的识别和细节处理方面表现较好,边界模糊区域的误分割现象较少。

在树木分割方面,所有模型在大面积树木区域的分割效果上表现良好;在细小树木区域的分割上 ResU-Net 及 AttResU-Net 的表现相对较优,能够较准确地分割出细小树木区域。

在小物体分割方面,TransUNet 和 Vgg-UNet 识别准确度较低,易将小物体与背景混淆;ResU-Net

及 AttResU-Net 识别效果相对较好,但在复杂背景下会出现误分类现象。

综上所述,TransUNet 和 Vgg-UNet 在不同类别的边界处理上不够精细,易产生误分类;ResU-Net 及 AttResU-Net 在边界处理上表现较好,特别是 AttResU-Net 能够更准确地处理不同类别的边界,减少误分类现象。

TransUNet 适合处理复杂场景;Vgg-UNet 适合大面积区域分割;ResU-Net 综合表现较好,适合细节和边缘处理较为重要的场景;AttResU-Net 在细节和边界重要的复杂场景上表现最佳,能够在复杂场景下对小物体进行分割和分类,在细节处理较为准确、在边界划分上较为平滑,是目前模型结构提取能力最优的模型,特别适合需要细致分割任务的情景。

2.3.2 图像识别模型性能评估

为定量评估模型的分割效果,使用 FloodNet 数据集进行 350 次训练,模型损失曲线趋于稳定后,使用测试集的 469 张图像评估模型性能。通过 mIoU、mPA、PA、mPrecision 和 mRecall 等指标,系统比较不同模型在分割任务中的综合性能,指标结果在改进 AttResU-Net 与 TransUNet、Vgg-UNet 和 ResU-Net 等模型中存在显著差异,不同分割模型在 FloodNet 数据集的评估指标对比见表 1。

表 1 不同分割模型在 FloodNet 数据集的评估指标对比

Table 1 Comparison of evaluation metrics of different segmentation models on the FloodNet dataset %

模型	mIoU	mPA	PA	mPrecision	mRecall
TransUNet	31.40	40.72	73.47	40.72	59.77
Vgg-UNet	66.71	77.88	89.85	80.21	77.88
ResU-Net	62.71	74.53	87.97	77.67	74.53
AttResU-Net	68.42	79.75	90.01	81.78	79.75

相比之下,TransUNet 表现逊色,其 mIoU、mPA、mPrecision 和 mRecall 指标显著低于其他模型,反映出 TransUNet 在 FloodNet 数据集上的分割效果不如其他模型,不适用于洪涝区域分割。与 ResU-Net 和 Vgg-UNet 相比,AttResU-Net 的各项指标均有明显提升,在分割精度和召回率上显示出优势,可用于洪涝区域分割。

为进一步分析模型在不同环境类型下的表现差异,测试图像按语义类别划分为“建筑物被淹”“建筑物未淹”“道路被淹”“道路未淹”“树木”“水体”等,这些类别对应城市积水区、干道交通区、植被区域、水边环境等典型洪涝灾害场景。针对这些类别,绘制改进 AttResU-Net、Vgg-UNet 和 ResU-Net 等模

型 IoU, Pixel Accuracy, Precision, Recall 对比图,如图 4 所示。




图 4 多类别性能指标对比

Fig. 4 Comparison of performance indicators in multiple categories

由图 4 可知:在建筑物未淹、道路被淹与道路未淹等关键场景类别中,AttResU-Net 在所有指标上均明显优于 Vgg-UNet 和 ResU-Net,在 Recall 与 Pixel Accuracy 方面表现尤为突出,表明该模型能够更准确地识别洪涝关键区域。在树木、水体、车辆等复杂背景中,AttResU-Net 的边界分割处理平滑,体现出其较强的细节还原与边界识别能力。

改进 AttResU-Net 模型通过采用 ResNet50 作为编码器、解码器并引入自注意力机制,实现模型特征提取和选择能力提升,可高质量地处理复杂情景下的图像分割任务。尽管 AttResU-Net 在多项指标中表现突出,但仍存在一定局限:在严重遮挡或遥感图像质量较差场景下,可能出现误分类或边界识别不清等问题;模型结构较复杂,推理时间与计算资源需求相对较高,在资源受限的嵌入式设备中运行较慢。洪涝灾害识别的准确性和及时性对制定有效的应急救援计划、评估受灾区域安全等级至关重要,因此,未来研究可进一步优化模型结构,提升分割精度和运行效率。

3 结 论

1) 改进的 AttResU-Net 模型通过结合 ResNet50 的特征提取能力和增加自注意力机制的动态关注能力,显著提升了对洪涝灾害图像识别的准确性,特别是在复杂背景下对区域分割和细节还原能力表现突出。

2) 使用 FloodNet 数据集训练不同模型,试验结果表明:改进 AttResU-Net 模型的像素准确率为 90.01%、平均精度为 81.78%、平均召回率为 79.75%,综合性能优于 TransUNet, Vgg-UNet, ResU-Net 模型。

3) AttResU-Net 模型在复杂背景特别是城镇环境下能够精确识别洪涝灾害的影响区域,为洪涝灾害特别是城镇洪涝灾害监测和应急响应提供可靠的技术支持。在模型优化方面,未来可从不同角度深入研究,如简化模型结构以提升运算效率,适应实时监测和边缘设备的应用需求;引入多种遥感数据如合成孔径雷达、光学和热红外,提高模型在多源信息

下的适应性;拓展到森林火灾、滑坡、泥石流等其他自然灾害识别任务中,验证其泛化能力。

参 考 文 献

- [1] LATIF S, SIMONOVIC S P. Compounding joint impact of rainfall, storm surge and river discharge on coastal flood risk: an approach based on 3D fully nested Archimedean copulas [J]. *Environmental Earth Sciences*, 2023,82:DOI:10.1007/s12665-022-10719-9.
- [2] 周月华, 彭涛, 史瑞琴. 我国暴雨洪涝灾害风险评估研究进展[J]. *暴雨灾害*, 2019,38(5):494-501.
ZHOU Yuehua, PENG Tao, SHI Ruiqin. Research progress on risk assessment of heavy rainfall and flood disasters in China [J]. *Torrential Rain and Disasters*, 2019,38(5):494-501.
- [3] 张海凤, 孔铎, 方建. 超常规极端暴雨洪涝灾害应对的国际比较研究:以 2021 年中美德暴雨洪涝灾害为例[J]. *水利水电技术:中英文*, 2023,54(7):1-13.
ZHANG Haifeng, KONG Feng, FANG Jian. International comparative study on coping with flood waterlogging disaster from extraordinary rainstorm: taking rainstorm flood waterlogging disasters in China, America and Germany in 2021 as study cases [J]. *Water Resources and Hydropower Engineering*, 2023,54(7):1-13.
- [4] YANG Kaixin, ZHANG Sujie, YANG Xinran, et al. Flood detection based on unmanned aerial vehicle system and deep learning[J]. *Complexity*, 2022,2022(1):1-9.
- [5] 孙世金, 孙永玲, 刘晓, 等. 基于 Landsat 8 影像的冰川边界提取方法研究:以喀喇昆仑区域为例[J]. *遥感技术与应用*, 2024,39(6):1 363-1 372.
SUN Shijin, SUN Yongling, LIU Xiao, et al. Research on glacier boundary extraction method based on Landsat-8 image: taking the Karakoram region as an example [J]. *Remote Sensing Technology and Application*, 2024, 39 (6): 1 363-1 372.
- [6] MIAO Tian, ZENG Hongcheng, WANG He, et al. A fast extraction method of flood areas based on iterative threshold segmentation using spaceborne SAR data[J]. *Systems Engineering and Electronics*, 2022,44(9):2 760-2 768.
- [7] 李昕悦, 张锦, 贾笑怡, 等. 适用于城市洪水的水体提取方法对比与分析[J]. *地下水*, 2020,42(5):179-183.
LI Xinyue, ZHANG Jin, JIA Xiaoyi, et al. Comparison and analysis of water extraction methods suitable for urban flood[J]. *Ground Water*, 2020,42(5):179-183.
- [8] 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.
WANG Jingming, WANG Shixin, WANG Futao, et al. Flood inundation region extraction method based on Sentinel-1 SAR data[J]. *Journal of Catastrophology*, 2021,36(4):214-220.
- [9] 郭玮, 袁宏永, 薛明, 等. SAR 影像洪水淹没范围深度学习提取方法[J]. *中国安全科学学报*, 2022,32(4):177-184.
GUO Wei, YUAN Hongyong, XUE Ming, et al. Flood inundation area extraction method of SAR images based on deep learning[J]. *China Safety Science Journal*, 2022,32(4):177-184.
- [10] LI Wenning, LI Yi, GONG Jianhua, et al. Urban water extraction with UAV high-resolution remote sensing data based on an improved U-NET model[J]. *Remote Sensing*, 2021,13(16):DOI: 10.3390/rs13161365.
- [11] ZHAO Jie, LI Yu, MATGEN P, et al. Urban-aware U-NET for large-scale urban flood mapping using multitemporal Sentinel-1 intensity and interferometric coherence[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022,60:1-21.
- [12] KIM J, KIM H, KIM D, et al. Deep learning-based flood area extraction for fully automated and persistent flood monitoring using cloud computing[J]. *Remote Sensing*, 2022,14(24):DOI: 10.3390/rs14246373.
- [13] FENG Wenqing, SUI Haigang, HUANG Weiming, et al. Water body extraction from very high-resolution remote sensing imagery using deep U-NET and a super pixel-based conditional random field model[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018,16(4):618-622.
- [14] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016:770-778.
- [15] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: learning where to look for the pancreas[J]. *arXiv*

Preprint arXiv, 2018;DOI: 10.48550/arXiv.1804.03999.

[16] RAHNEMOONFAR M, CHOWDHURY T, SARKAR A, et al. Flood net: a high-resolution aerial imagery dataset for post flood scene understanding[J]. IEEE Access, 2021,9:89 644–89 654.

[17] 徐康, 朱茂, 贺秋华, 等. 一种基于 TransUNet 的 SAR 影像水体提取及洲滩面积变化监测应用[J]. 测绘科学, 2024,49(2):55–64.

XU Kang, ZHU Mao, HE Qiuhua, et al. Water extraction from SAR images based on TransUNet and its application in sandbar area change monitoring[J]. Science of Surveying and Mapping, 2024,49(2):55–64.

[18] WU Ji, JIN Yaqiu, SHI Jiancheng, et al. Special issue on the 2016 IEEE international geoscience and remote sensing symposium[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017,10(6): 2 428–2 430.

[19] 江松, 李研博, 何旭乾, 等. 基于无人机影像深度学习的滑坡灾害智能识别[J]. 中国安全科学学报, 2024, 34(7):229–238.

JIANG Song, LI Yanbo, HE Xuqian, et al. Intelligent identification of landslide disaster based on deep learning of UAV images [J]. China Safety Science Journal, 2024,34(7):229–238.



作者简介：钟兴润（1984—），女，陕西榆林人，硕士，讲师，主要从事建筑安全工程、土木工程建设与管理、结构安全检测与鉴定等方面的研究。E-mail:283808185@qq.com。



《中国安全科学学报》被 Ei 数据库收录

2025 年 4 月,《工程索引》(Ei Compindex)发布最新收录期刊目录,《中国安全科学学报》(简称《学报》)成功被收录。

COMPENDEX SOURCE LIST: UPDATED APRIL 2, 2025					
PRINT ISSN	ONLINE ISSN	CHINESE TITLE (中文刊名)	TRANSLITERATED TITLE (刊名翻译)	ENGLISH/TRANSLATED TITLE (英文刊名)	LANGUAGE (语言)
10014632	-	中国铁道科学	Zhongguo Tiedao Kexue	China Railway Science	Chinese
10033033	-	中国安全科学学报	Zhongguo Anquan Kexue Xuebao	China Safety Science Journal	Chinese
10079289	-	中国表面工程	Zhongguo Biaomian Gongcheng	China Surface Engineering	Chinese

自 1991 年创刊以来,《学报》始终秉承“立足安全科技前沿,服务国家重大需求”的办刊宗旨,坚持“学术性、权威性、应用性、信息性”的办刊原则,在安全生产、应急管理、公共安全、防灾减灾、职业健康等领域搭建高水平学术交流平台,发表众多具有创新性和实践价值的研究成果。多年来,《学报》的学术影响力持续攀升,先后入选“中国科技核心期刊”“中文核心期刊”和“中国科学引文数据库核心期刊(CSCD 核心期刊)”,入选中国科技期刊卓越行动计划梯队期刊(一期、二期),并被美国《化学文摘社》(CAS)、Scopus 等国际知名数据库收录。此次成功被 Ei Compindex 数据库收录,更是对《学报》学术地位的有力肯定。