

DOI:10.3969/j.issn.1003-5060.2024.11.021

基于改进 Swin-UNet 网络的高分辨率遥感影像建筑物提取

袁啸宇, 李振轩, 高飞

(合肥工业大学 土木与水利工程学院, 安徽 合肥 230009)

摘要:针对传统人工提取方法目前在建筑物提取任务中自动化水平低,以及现有的卷积神经网络(convolutional neural network, CNN)、UNet 等深度学习方法在遥感影像建筑物提取中边缘提取效果差、提取不完整等问题,文章提出一种基于改进的 Swin-UNet 网络模型的建筑物自动提取方法。新网络模型在原 Swin-UNet 网络结构基础上,采用跨块注意力机制(cross-attention block, CAB)取代原网络的 Swin Transformer 块来构建新的网络体系,在武汉大学航空(WHU)建筑数据集和美国马萨诸塞州建筑物数据集建筑物提取试验中验证了模型的适用性。研究表明,该方法优于支持向量机(support vector machine, SVM)算法及基于传统的深度学习方法,具有良好的分割精度和鲁棒泛化能力。

关键词:高分辨率遥感影像;深度学习;建筑物提取;Swin-UNet 网络结构

中图分类号:P237 **文献标志码:**A **文章编号:**1003-5060(2024)11-1571-09

High-resolution remote sensing image building extraction based on improved Swin-UNet network

YUAN Xiaoyu, LI Zhenxuan, GAO Fei

(School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: In view of the low automation level of traditional artificial extraction methods in building extraction tasks, and the poor and incomplete edge extraction of existing deep learning methods such as convolutional neural network(CNN) and UNet in remote sensing image building extraction, this paper presents an automatic building extraction method based on improved Swin-UNet network model. Based on the original Swin-UNet network structure, the new network model uses cross-attention block(CAB) to replace the Swin Transformer block of the original network to build a new network system. The applicability of the model is verified in the building extraction experiments of Wuhan University(WHU) Aerial Building Dataset and Massachusetts Buildings Dataset. The results show that the proposed method is superior to support vector machine(SVM) algorithm and traditional deep learning methods, and has good segmentation accuracy and robust generalization ability.

Key words: high-resolution remote sensing image; deep learning; building extraction; Swin-UNet network structure

高分辨率遥感影像覆盖范围大、信息量大、更新速度快^[1],对于地面信息的获取十分重要。高分辨率遥感影像的建筑物提取对城市空间类型变

化和动态监测,城市空间数据库的更新发展及数字化城市的创建具有重要意义^[2]。利用遥感影像进行建筑物提取从 20 世纪 80 年代发展至今,根

收稿日期:2023-02-27;修回日期:2023-04-14

基金项目:安徽省自然科学基金资助项目(2208085QD105);中央高校基本科研业务费专项资金资助项目(JZ2021HGTA0167)

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;

高飞(1962—),男,安徽天水人,合肥工业大学教授,博士生导师。

据其自动化程度可分为人工(目视解译)提取、半自动化提取和自动化提取 3 个阶段^[3]。文献[4]针对高分辨率遥感影像自动化解译技术难度大、适用性差等问题,提出人工目视解译为遥感影像解译的主要方法,但目视解译需耗费大量时间和精力,且精度难以达到要求。此后引入半自动化提取方法,如支持向量机(support vector machine, SVM)算法、K-means 聚类算法。文献[5]针对高光谱遥感影像分类过程中面临的实际问题和影像数据本质特性,将 SVM 算法应用于高光谱遥感影像的分类中。但 SVM 算法只适用于图像的二分类,在解决数据实际应用中的多分类问题方面效果并不理想^[6]。深度学习成为图像识别、提取中效果最好的方法,现有的深度学习方法卷积神经网络(convolutional neural network, CNN)^[7]、UNet^[8]、UNet++^[9-10]、DeepLabV3+^[11]等网络虽然在医学图像分割领域表现出的性能优异,但在遥感影像建筑物提取中会出现建筑物轮廓提取不清晰、存在细碎的小斑点、遗漏部分小型建筑物等问题^[12-14]。本文以高分辨率遥感影像作为数据源,提出一种新的基于改进的 Swin-UNet 网络模型进行建筑物提取,此模型保留原 Swin-UNet 网络体系结构,采取跨块注意力机制

(cross-attention block, CAB)^[15]取代原网络结构编码器和解码器中的 Swin Transformer 块。采用公开的武汉大学航空(WHU)建筑数据集进行建筑物提取研究,并在美国马萨诸塞州建筑物数据集上验证本文方法的适用性。

1 方 法

本文研究的高分辨率遥感影像建筑物提取架构主要分为 3 个部分。第 1 部分是数据处理阶段,包括对选取的样本数据集进行数据增强,输入到网络模型中进行多次迭代训练和对比试验,确定出该网络的最理想的模型参数,并利用最优的网络模型进行高分辨率遥感建筑物的提取。第 2 部分主要针对 Swin-UNet 网络应用在道路及高分辨率遥感影像建筑物提取中精度不够高的问题,提出了基于改进 Swin-UNet 网络的建筑物提取方法。通过引入 CAB,降低了实际操作难度,提高了捕获全局信息能力,并避免了计算量的增加。在此基础上构建新的分辨率遥感影像建筑物提取框架,提高遥感影像建筑物提取精度。第 3 部分在完成建筑物提取的基础上,对建筑物提取结果进行比对,分别从可视化提取结果和提取精度进行分析。本文技术路线如图 1 所示。

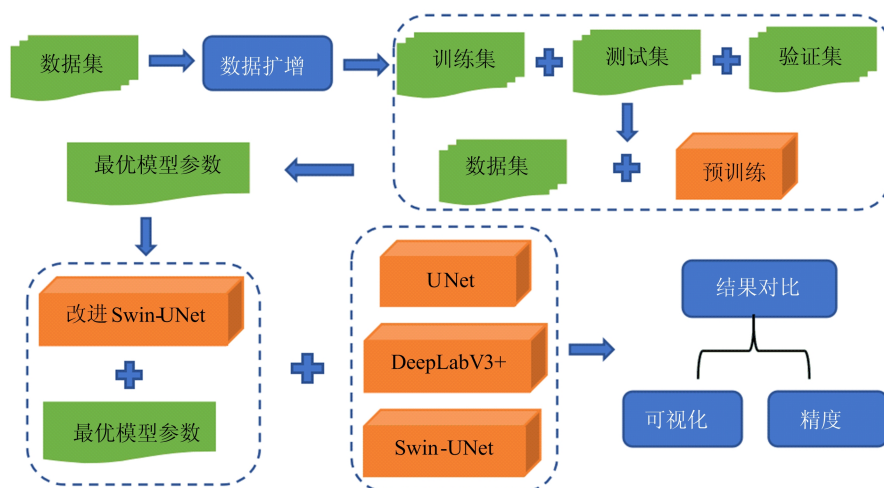


图 1 基于改进 Swin-UNet 网络的建筑物提取流程图

1.1 改进的 Swin-UNet 网络

基础 Swin-UNet 网络结构整体框架与 UNet 结构类似,将 UNet 结构中的编码器和解码器用 Swin Transformer 块替代,整体框架保留 Transformer 的优势。Swin-UNet 由编码器、瓶颈、解码器和跳跃连接组成。编码器、瓶颈和解码器基于 Swin Transformer 块构建。编码器将输入图

像转换为序列嵌入,这里将输入的遥感建筑物图像分割成大小为 4×4 的非重叠补丁。通过这种划分方法,每个补丁的特征维数变为 $4 \times 4 \times 3 = 48$ 。将投影的特征维度放入线性嵌入层,转换后的补丁标记经过几个 Swin Transformer 块和补丁合并层生成分层特征表示,其中补丁合并层负责下采样和增加维度,Swin Transformer 块负责

特征表示学习。解码器由 Swin Transformer 块和补丁扩展层组成。补丁扩展层用于上采样,相邻维度的特征图通过补丁拓展层之后,特征维数变为原来 1/2,分辨率更高,最终重塑为一个大的特征地图。最后一个补丁扩展层进行 4×上采样,将特征映射的分辨率恢复到原始输入分辨率

($W \times H$)。为减少降采样过程产生的空间信息损失, Swin-UNet 网络中加入了跳跃连接,把提取的上下文特征与编码器的多尺度特征进行融合,恢复特征图的空间分辨率并进行进一步的分割预测^[16-18]。基础 Swin-UNet 网络结构如图 2 所示。

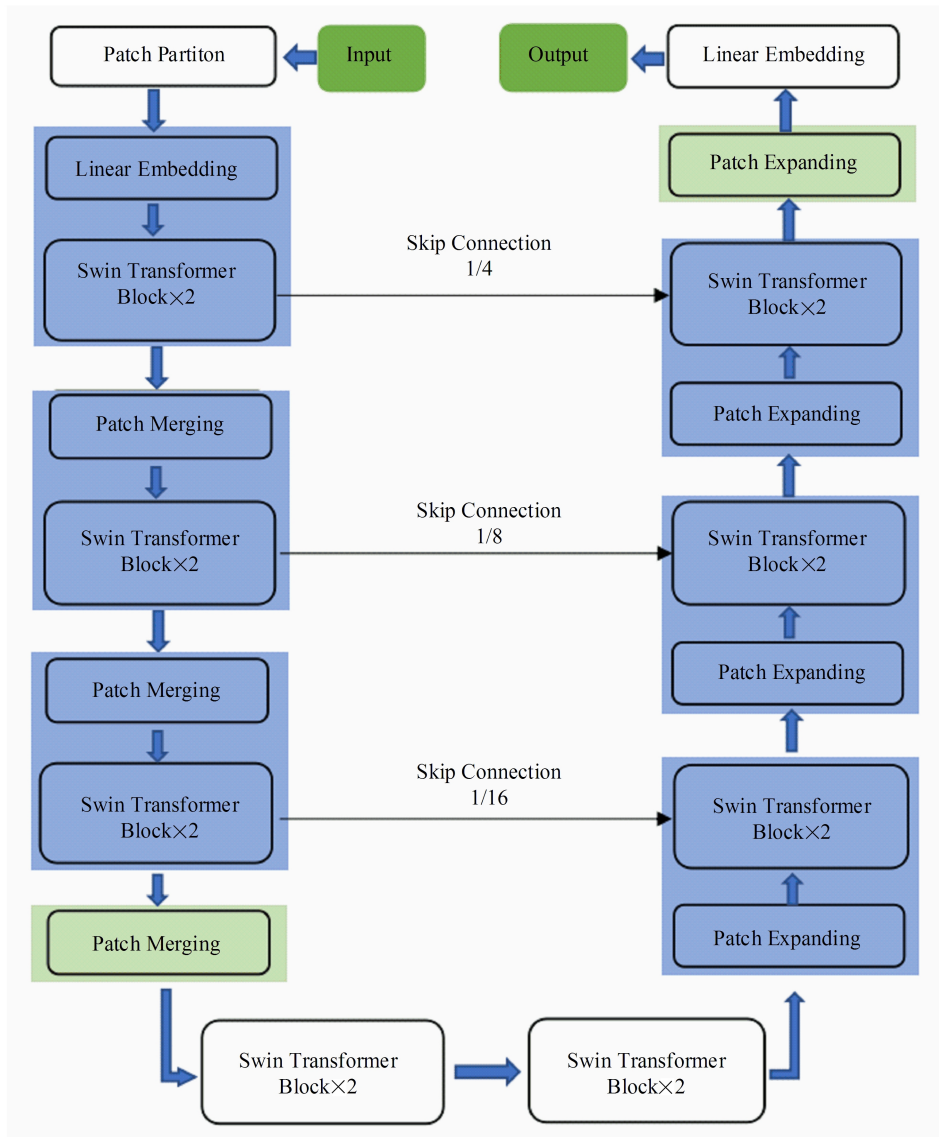


图 2 基础 Swin-UNet 结构图

Swin-UNet 网络已经在视觉任务和自然语言处理(natural language processing, NLP)任务中取得了不错的效果,但 Swin Transformer 块结构中加入滑动窗口多头自注意力(shifted-window multi-head self-attention, SW-MSA)机制模块操作时,感受野得到增大,对不同尺寸的输入要设计不同的网络,需要重新开始训练,在实际操作中实现困难。另一方面, Swin Transformer 中仅仅是在局部以及相邻斑块之间进行交互,缺乏

全局信息交互,导致捕获全局信息能力较差,因此把 Swin-UNet 网络运用在在高分辨率遥感影像的地物信息提取上难以取得和视觉任务中一样优异的性能。为了解决上述问题,引入 CAB, Cross-attention 块的引入一方面可以有效地进行全局信息交互,同时可以避免随着输入分辨率的增加而导致计算量的增加。

CAB 结构如图 3 所示,改进后的 Swin-UNet 网络结构如图 4 所示。

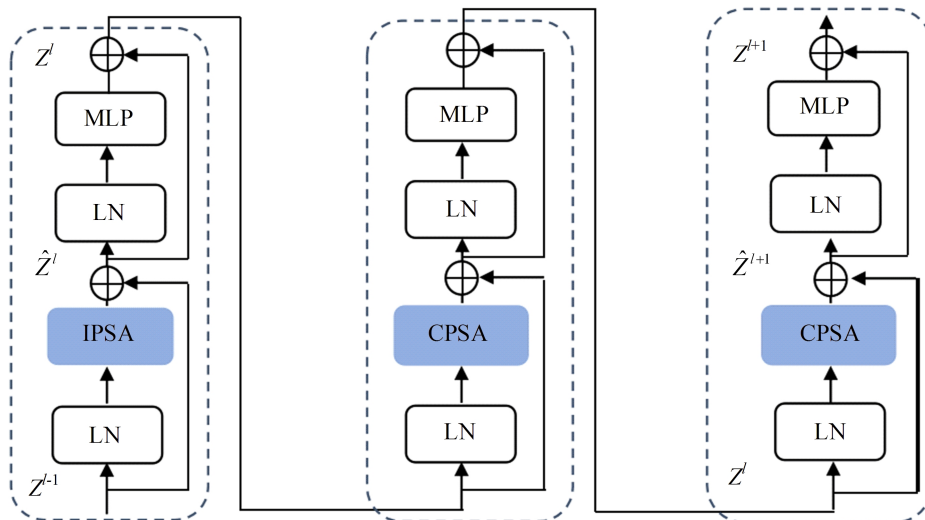


图 3 CAB 结构图

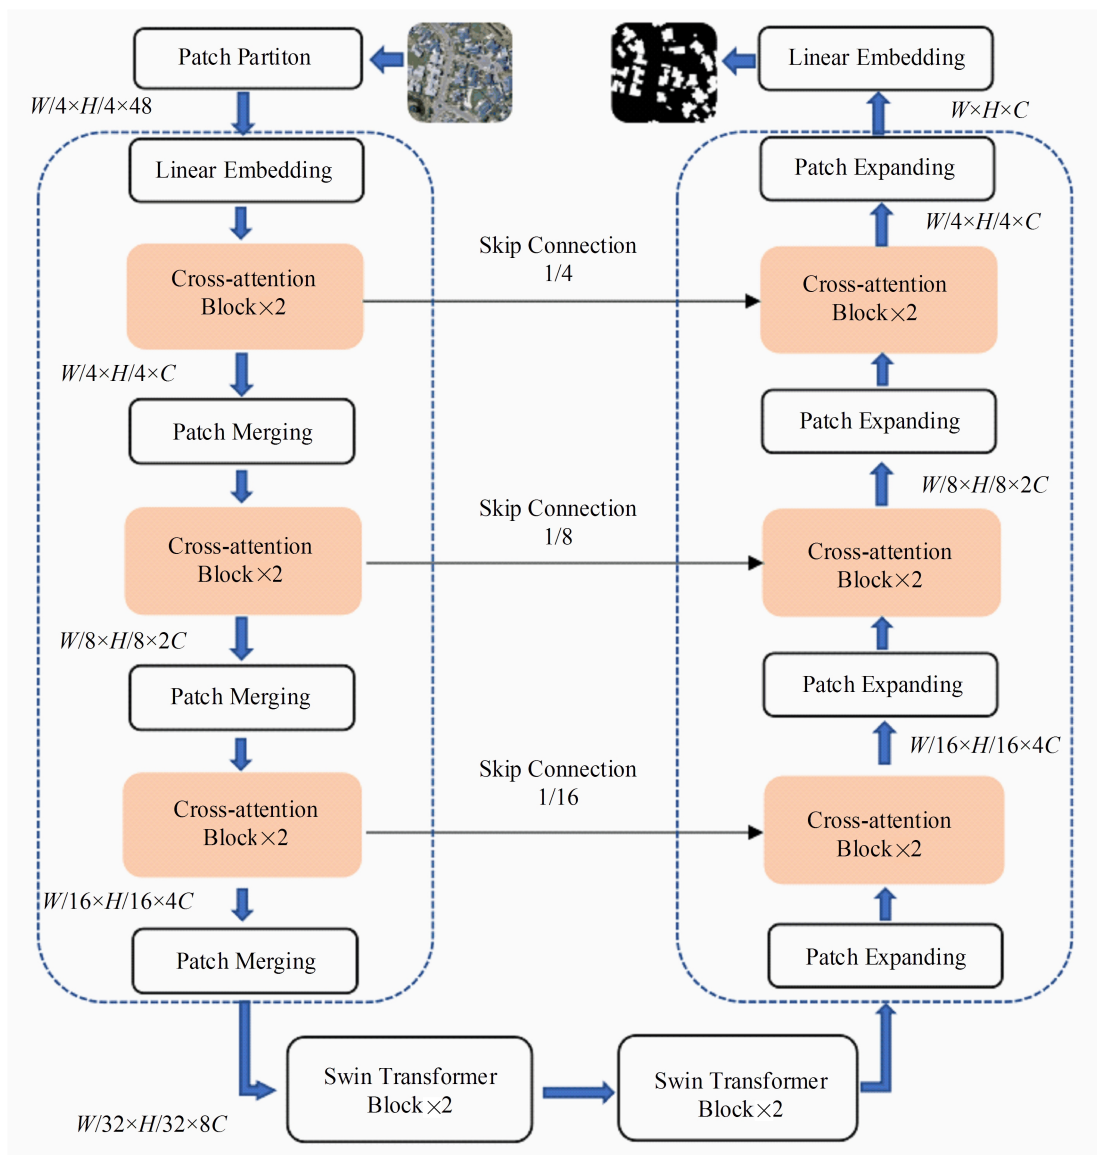


图 4 改进的 Swin-UNet 网络结构

原 Swin Transformer 块中的 MSA 模块和 SW-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和所有像素计算。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:

$$\Omega(M_{\text{MSA}}) = 4h\omega C^2 + 2(h\omega)^2 C \quad (1)$$

$$\Omega(W_{\text{W-MSA}}) = 4h\omega C^2 + 2M^2 h\omega C \quad (2)$$

其中: h, ω 为特征图像的高度和宽度; C 为划分后的 patch 特征维度; M 为一个窗口里的 patch 数量。

Cross-attention 块受 CNN 中的局部卷积方法的启发,引入 IPSA(inner-patch self-attention) 模块,IPSA 模块将每个 patch 当做一个注意力范围,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。同时为确保整个画面的信息交换,引入 CPSA(cross-patch self-attention) 模块,CPSA 模块将每个通道特征图分离,将每个通道划分为 $H/N, W/N$ 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 模块计算量表达式如下:

$$\Omega(I_{\text{IPSA}}) = 2h\omega C^2 + M^2 h\omega C \quad (3)$$

$$\Omega(C_{\text{CPSA}}) = 4M^2 \omega C + 2(h\omega/M)^2 C \quad (4)$$

Cross-attention 块中 IPSA 模块和 CPSA 模块在实际操作过程中计算量约为原 Swin Transformer 块计算量的 $1/2$ 。因此,在原 Swin-UNet 网络结构的编码器和解码器部分用 Cross-atten-

tion 块替代 Swin Transformer 块,使得实际操作中的实现难度降低,避免了计算量的增加,另外可以提高捕获全局信息能力,在实际操作中进一步提高了遥感影像的地表信息提取精度。

2 试验数据

为验证本文方法的可行性,以 WHU 数据集作为试验数据集,通过试验证明改进的 Swin-UNet 网络在高分辨率遥感影像建筑物提取中的优势。

2.1 试验数据介绍

本研究所选取的数据集为 WHU,其航空影像数据集来自新西兰土地信息服务网站,地面分辨率降采样为 0.3 m ,选取的克赖斯特彻奇地区大约有 22 000 栋独立建筑物。将该区域内影像裁剪尺寸为 512×512 的影像,共 8 392 幅,并将图像划分为训练集(4 936 幅)、验证集(1 037 幅)和测试集(2 419 幅)3 个部分。

2.2 数据处理

数据增强一方面为提高样本质量,使训练出来的模型效果更好,增强模型泛化能力;另一方面通过样本的扩充来增加训练样本以防止模型训练过程中出现过拟合。本研究对样本数据进行垂直翻转、水平翻转、随机旋转和随机剪裁操作,处理过程如图 5 所示。

为进一步利用图像处理器(graphics processing unit, GPU)计算能力,提高计算效率,将数据集中的图像随机裁剪为 256×256 像素。最终得到 24 000 幅训练数据集和 8 000 幅同等尺寸的测试数据集。

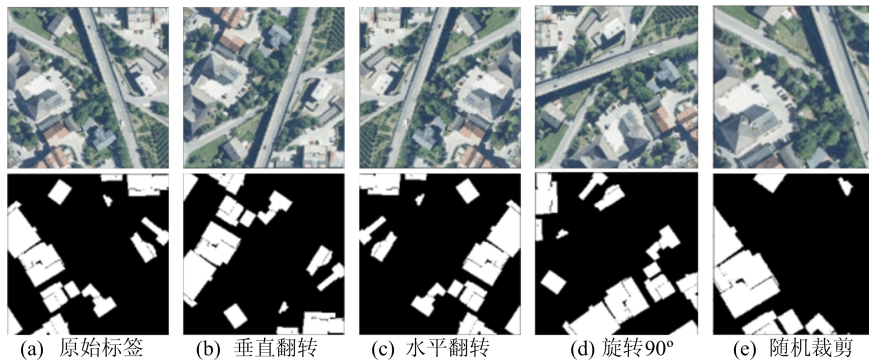


图 5 数据增强处理过程

3 试验与算法评价

3.1 硬件配置和参数设置

本试验所有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 RTX2060。试验过程中,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;epoch 设置为 50;为克服 GPU 内存的影响,batch size 值设为 8。改进的 Swin-UNet 模型的损失收敛函数与精度变化曲线如图 6 所示。由图 6 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,大约在第 40 次以后准确率趋于稳定,维持在 96.83%左右;损失函数值也在不断下降,最终稳定在 0.021 左右。




图 6 损失收敛函数值与精度变化曲线

为探究本文提出的改进的 Swin-UNet 网络在建筑物提取方面的优势,将传统机器学习方法 SVM、深度学习方法 UNet、DeepLabV3+、Swin-UNet 方法与本文方法进行对比试验。其中,SVM 算法在遥感图像处理平台中完成,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、DeepLabV3+、Swin-UNet 方法同样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 Swin-UNet 模型参数一致。

3.2 评价指标

本研究采用总体精度 O_{OA} 、查全率 R_{Recall} 、 F_1 值和平均交并比 M_{mIoU} 作为分割精度的评估标准。其中, O_{OA} 指图像中预测正确的建筑物和背景像元占有所有像元的比例; R_{Recall} 标签中某类别被预测正确的概率,即预测正确的建筑物像元占建筑物区域真值像元的比例; F_1 值是查准率和查全率的调和平均数; M_{mIoU} 是计算两集合的交集与其并集的重合比例,在本研究中,计算的是真实建筑物标签与模型提取的建筑物之间的交并比。各评估标准计算公式如下:

$$O_{OA} = \frac{T_{TP} + T_{TN}}{T_{TP} + F_{FN} + F_{FP} + T_{TN}} \quad (5)$$

$$R_{Recall} = \frac{T_{TP}}{T_{TP} + F_{FN}} \quad (6)$$

$$F_1 = \frac{T_{TP}}{T_{TP} + (F_{FP} + F_{FN})/2} \quad (7)$$

$$M_{mIoU} = \frac{T_{TP}}{T_{TP} + F_{FP} + F_{FN}} \quad (8)$$

其中: T_{TP} 为输入图像中含有标签信息的部分被正确识别为相对应的标签信息,本文指提取到实际建筑物的个数; T_{TN} 为输入图像中含有背景信息的部分被正确识别为相对应的背景信息; F_{FP} 为输入图像中含有背景信息的部分被错误识别为标签信息; F_{FN} 为输入图像中含有标签信息的部分被错误识别为背景信息。

4 试验结果与分析

4.1 可视化结果分析

为验证本文方法在建筑物自动提取方面的有效性和适用性,将改进的 Swin-UNet 方法与 UNet、DeepLabV3+、Swin-UNet 方法在同一训练环境中的提取结果进行可视化比较,分别采用 WHU 建筑物数据集和美国马萨诸塞州建筑物数据集进行试验和验证。

不同提取方法在 2 种建筑物数据集上的边缘提取效果对比如图 7 所示。图 7 中蓝色方框内为 3 种深度学习算法和本文方法效果差异较大的部分。对于 SVM 算法,其在 2 种建筑物数据集上的提取表现均不理想,提取结果存在大量噪声,细碎斑点较多,且在一些非建筑物的人造设施上出现了较为严重的错分问题。WHU 数据集中,UNet、DeepLabV3+ 和 Swin-UNet 提取结果中非建筑物的错分现象大大减少,但在建筑物边缘的提取上效果欠佳,边缘提取不够清晰。从图 7a 可看出,以上深度学习方法在两栋相连建筑物的边缘部分提取上均出现了分离,图 7b 的边缘提取不够清晰。而本文方法在图 7a 中较好地识别了连接部分,在图 7b 中的建筑物边缘把控得更好。马萨诸塞州数据集中,从图 7c、图 7d 的提取结果来看,基于以上 3 种深度学习方法提取的方框内的建筑物边缘未分离,出现了连接。本文方法对相邻两栋建筑物较好地完成了分离。

因此,改进的 Swin-UNet 方法与 UNet、DeepLabV3+、Swin-UNet 提取方法相比,在影像边缘细节的分类效果上更优,对建筑物的边缘把控得更好,轮廓更清晰。

不同提取方法在 2 种建筑物数据集中细小建筑物提取效果对比如图 8 所示。

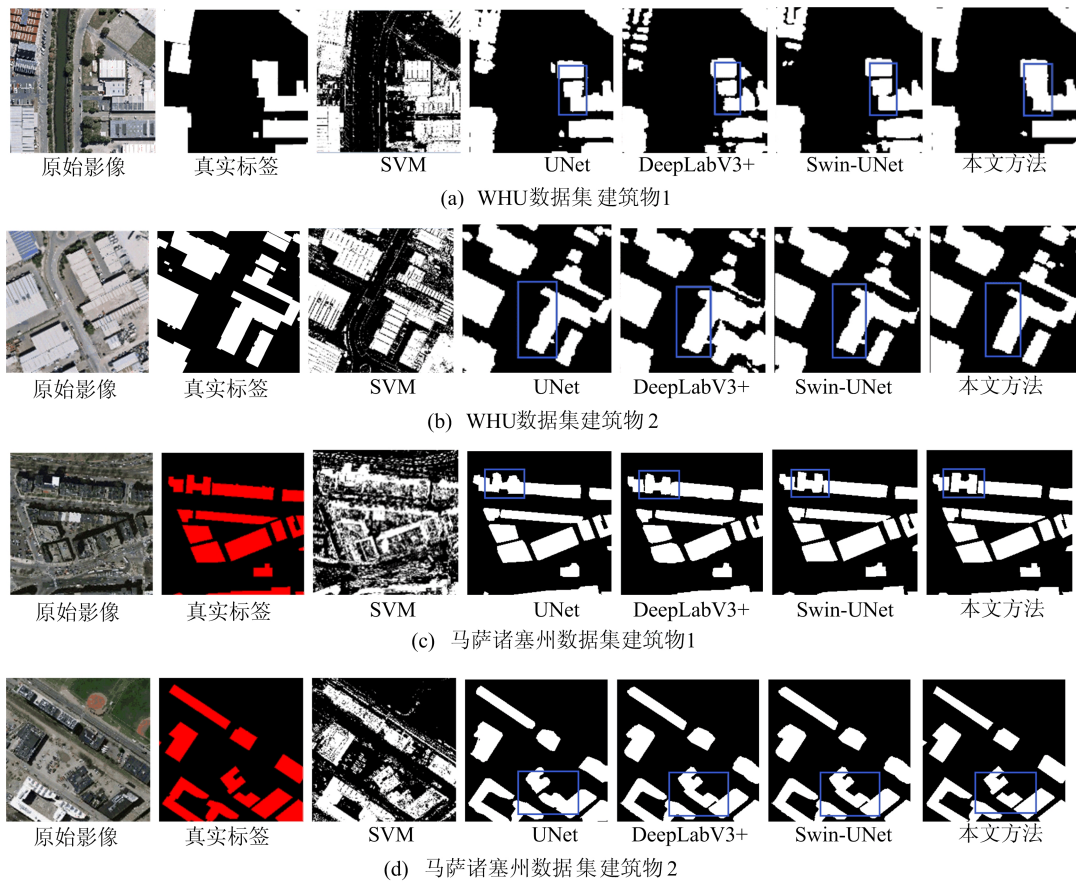


图 7 不同数据集的建筑物边缘提取效果对比

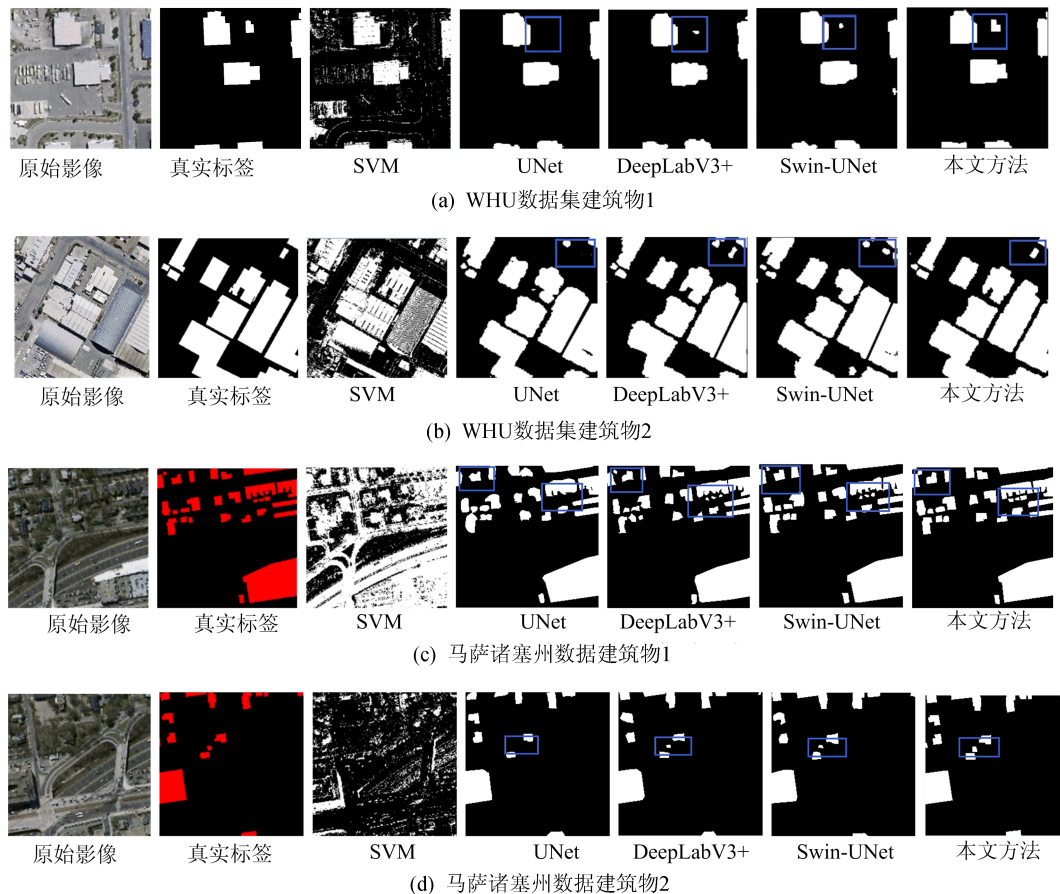


图 8 不同数据集的细小建筑物提取效果对比

在 WHU 数据集上,UNet、DeepLabV3+与 Swin-UNet 方法在图 8a 中的建筑物提取上出现漏检的问题。对于图 8b,以上 3 种方法错误将小型非建筑人工设施划分为建筑物,而本文方法对图 8a、图 8b 中的小型建筑物提取较为准确。马萨诸塞州数据集中,UNet 方法同样对图 8c、图 8d 中的小型建筑物出现了漏提,DeepLabV3+和 Swin-UNet 方法虽提取到部分建筑物,但不够完整。本文方法比 DeepLabV3+和 Swin-UNet 方法提取到建筑物更完整且不存在漏检的情况。

综上所述,本文方法与以上 3 种深度学习方法相比,在小型建筑物提取上表现更出色,基本做到提取效果与真实标签一致。

4.2 精度比较与分析

利用 O_{OA} 、 M_{mIoU} 、 R_{Recall} 和 F_1 值作为评估标准对建筑物自动提取结果进行量化分析。在 WHU 数据集和马萨诸塞州数据集中的定量评价结果分别见表 1、表 2 所列。

表 1 WHU 数据集定量评价结果 %

提取方法	O_{OA}	M_{mIoU}	R_{Recall}	F_1
SVM	70.19	61.24	72.88	63.73
UNet	90.90	69.39	89.03	80.75
DeepLabV3+	92.56	73.45	91.08	81.88
Swin-UNet	93.07	72.78	90.33	83.14
本文方法	96.83	77.63	93.79	85.24

表 2 马萨诸塞州数据集定量评价结果 %

提取方法	O_{OA}	M_{mIoU}	R_{Recall}	F_1
SVM	64.07	53.29	60.12	54.78
UNet	91.34	71.67	86.59	82.35
DeepLabV3+	92.77	74.55	89.78	80.23
Swin-UNet	91.83	72.34	91.33	84.99
本文方法	95.31	74.45	91.70	86.13

结果表明,SVM 算法在高空间分辨率遥感影像建筑物的提取方面总体精度最低,提取效果不理想。与 SVM 算法相比,深度学习方法 UNet、DeepLabV3+与 Swin-UNet 的各个指标值远优于 SVM 算法,在大部分建筑物的提取上解决了 SVM 存在的错分问题,但部分细微建筑物被忽略,细碎的小斑点较多。本文方法相较于 SVM 算法在两数据集的总体精度上提高了 30%左右,相较于 UNet、DeepLabV3+、Swin-UNet,在 O_{OA} 、 M_{mIoU} 及 F_1 均有所提高,经过 4.1 分析得知,表现在对建筑物边缘及细小建筑物提取方面的改进,对细小建筑物的提取更准确,且对边缘细节处理更加完善。从表 1、表 2 可以看出,本文方法所得到结果为定量评价最优结果。

5 结 论

本文提出一种基于改进的 Swin-UNet 网络模型的建筑自动提取方法,使用 WHU 建筑物数据集,完成数据集增强、模型训练、建筑物提取以及精度评估,通过试验证明了本文方法可以有效地实现高分辨率遥感影像建筑物提取,并在美国马萨诸塞州建筑物数据集上充分验证了其适用性。

1) 以 WHU 建筑物数据集和马萨诸塞州建筑物数据集作为试验数据集,使用改进的 Swin-UNet 图像语义分割算法对遥感影像中的目标建筑物进行精确提取。将其与 SVM、UNet、DeepLabV3+、Swin-UNet 这 4 种方法进行对比分析得知,SVM 算法在高分辨率遥感影像中提取出的不同类别建筑物之间分界线不明显,存在大量漏检、误检现象,边缘模糊,分类精度较低;从试验结果可知,SVM 算法的各个定量评价指标均较低,不适合用于高分辨率遥感影像对建筑物的精确提取。

2) 在利用本文提出的改进的 Swin-UNet 方法以及 UNet、DeepLabV3+、Swin-UNet 这 3 种方法对高分辨率遥感影像进行建筑物分类提取的结果中,总体精度均超过 90%,但相比改进的 Swin-UNet 方法所获得的结果在边缘细节的分类效果上更优,对建筑物的边缘提取效果更清晰、漏检建筑物大大减少。通过对以上 4 种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 Swin-UNet 网络对目标建筑物的提取效果更好、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 Swin-UNet 网络提取方法仍存在一些不足,一方面表现在面对遥感影像建筑物提取时鲁棒性不够强,且运行速度偏慢,导致模型训练时间偏长,后续研究中将研究如何进一步对网络模型简化以及削减模型计算量。另一方面,表现在该方法虽然目前在二分类提取任务中精度相比于先前的深度学习方法有较大提升,但其他优势类别的精度尚未得到保证,因此目前只适用于二分类场景的提取,后续研究将继续针对如何适用于多分类提取场景进行探索和改进。

[参 考 文 献]

- [1] 何直蒙,丁海勇,安炳琪. 高分辨率遥感影像建筑物提取的空洞卷积 E-Unet 算法[J]. 测绘学报,2022,51(3):457-467.

- [2] 丁育萱,邹进贵,朱晓康. 利用高分辨率 DSM 和 DOM 自动提取城市建筑物区域[J]. 测绘地理信息, 2021, 46(6): 86-89.
- [3] 魏征,杨必胜,李清泉. 车载激光扫描点云中建筑物边界的快速提取[J]. 遥感学报, 2012, 16(2): 286-296.
- [4] 杨乐. 高分辨率遥感影像解译方法与对比分析[J]. 经纬天地, 2021(5): 42-45.
- [5] 丁胜锋. 基于 SVM 的高光谱遥感影像集成分类方法研究[D]. 阜新: 辽宁工程技术大学, 2018.
- [6] 王立国,杨峰,石瑶,等. 基于 3D-CNN 的高光谱遥感图像分类算法[J]. 测绘通报, 2022, 39(1): 96-105.
- [7] 张华,郑祥成,郑南山,等. 基于 MAEU-CNN 的高分辨率遥感影像建筑物提取[J]. 地球信息科学学报, 2022, 24(6): 1189-1203.
- [8] 金澍,关沫,边玉婵,等. 基于改进 U-Net 网络的遥感影像建筑物提取方法[J]. 激光与光电子进展, 2023, 60(4): 59-65.
- [9] FATEMEH H, HOSSEIN K, BAGHER M, et al. Automatic microscopic diagnosis of diseases using an improved UNet++ architecture[J]. Tissue and Cell, 2022, 16(1): 145-152.
- [10] 吕少云,李佳田,阿晓蓉,等. Res_ASPP_UNet++: 结合分离卷积与空洞金字塔的遥感影像建筑物提取网络[J]. 遥感学报, 2023, 27(2): 502-519.
- [11] 黄聪,杨珺,刘毅,等. 基于改进 DeeplabV3+ 的遥感图像分割算法[J]. 电子测量技术, 2022(4): 21-24.
- [12] GLINKA S, OWERK T, TOMASZKIEWICZ K. Using open vector-based spatial data to create semantic datasets for building segmentation for raster data[J]. Remote Sensing, 2022, 14(12): 341-346.
- [13] 郭文,张莽. 基于注意力增强全卷积神经网络的高分卫星影像建筑物提取[J]. 国土资源遥感, 2021, 33(2): 100-107.
- [14] 陶超,谭毅华,蔡华杰,等. 面向对象的高分辨率遥感影像城区建筑物分级提取方法[J]. 测绘学报, 2010, 39(1): 39-45.
- [15] CAI W J, WANG Y F, MA J H, et al. CAN: effective cross features by global attention mechanism and neural network for ad click prediction[J]. Tsinghua Science and Technology, 2022, 27(1): 186-195.
- [16] CAO H, WANG Y, CHEN J, et al. Swin-unet: unet like puretransformer for medical image segmentation[C]//European Conference on Computer Vision. Cham: Springer, 2022: 205-218.
- [17] 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.
- [18] GAO Z J, CHEN L. Research on semantic segmentation method of macular edema in retinal oct images based on improved swin-unet[J]. Electronics, 2022, 11(15): 31-34.

(责任编辑 吴亮)

(上接第 1570 页)

- [14] MARBURG S. The burton and miller method; unlocking another mystery of its coupling parameter[J]. Journal of Computational Acoustics, 2016, 24(1): 1550016.
- [15] 布列霍夫斯基赫. 分层介质中的波[M]. 2 版. 杨训川, 译. 北京: 科学出版社, 1985.
- [16] 李家亮,林建恒,郭圣明,等. 浅海波导界面对点源振速方向的影响[J]. 应用声学, 2015(3): 249-254.
- [17] MESSIAH A. Quantum mechanics [M]. Amsterdam: North-Holland Publishing Company, 1962: 1054-1060.
- [18] COIFMAN R, ROKHLIN V, WANDZURA S. The fast multipole method for the wave equation; a pedestrian prescription[J]. IEEE Antennas and Propagation Magazine, 1993, 35(3): 7-12.
- [19] 黎胜,赵德有. 半空间内结构声辐射研究[J]. 船舶力学, 2004, 8(1): 106-112.
- [20] NELL C W, GILROY L E. An improved BASIS model for the BeTSSi submarine; TR 2003-2009: 199 [R]. Canada-Atlantic; Defence Research and Development, 2003.

(责任编辑 胡亚敏)

· 信息与动态 ·**《合肥工业大学学报(自然科学版)》专栏征稿启事**

为了贯彻落实党的二十大精神,紧密围绕科教兴国战略、人才强国战略、创新驱动发展战略,《合肥工业大学学报(自然科学版)》设置“机器人与人工智能”“环境污染与防治”两个专栏,面向国内外专家学者征集“机器人与人工智能”“环境污染与防治”领域的原创性学术论文、专题综述;稿件一经录用将优先刊发。

来稿要求政治导向正确、论证充分、具有较强的引领性和创新性。格式要求参见《合肥工业大学学报(自然科学版)》网页投稿指南的征稿简则和投稿模板。

在线投稿网址: <http://xbzss.hfut.edu.cn/xbzk.html>。