引文格式:甄杰,祁俊杰,王勇,等.面向应急通信选址的增强卷积神经网络山顶点快速提取方法[J].武汉大学学报(信息科学版),2025,50(6):1042-1053.DOI:10.13203/j.whugis20250097

Citation:ZHEN Jie,QI Junjie,WANG Yong,et al.A Rapid Extraction Method of Summit Point for Emergency Communication System Siting Based on Enhanced Convolutional Neural Network[J].Geomatics and Information Science of Wuhan University,2025,50(6):1042-1053.DOI:10.13203/j.whugis20250097

面向应急通信选址的增强卷积神经网络山顶点快速提取方法

甄　杰[1]　祁俊杰[1,2]　王　勇[1]　徐胜华[1]　刘纪平[1]

1　中国测绘科学研究院,北京,100036

2　辽宁工程技术大学测绘与地理科学学院,辽宁　阜新,123000

摘　要:为解决重特大自然灾害发生时应急通信网络快速构建及优化部署问题,通过数字高程模型与等高线、坡度、坡向融合的方法制作山顶点特征数据集,提升山顶区域特征信息,给出应急通信山顶区域筛选条件,提出适应多尺度山顶区域定位的增强更快速区域卷积神经网络算法模型,并针对大区域进行拆分、检测再合并,提高山顶区域识别效果,运用局部极大值方法实现了应急通信山顶点的精确化提取。所提改进算法模型与其他模型对比,均值平均精度达到94.92%,山顶点提取的准确度达到94.2%,以此为通信节点的信号有效覆盖率达到80.56%,可视率达到77.43%,均优于正反地形法和邻域分析法。

关键词:卷积神经网络;应急通信选址;山顶点提取;信号覆盖;可视域分析

中图分类号:TP208　　**文献标识码**:A　　**收稿日期**:2025-03-10

DOI:10.13203/j.whugis20250097　　**文章编号**:1671-8860(2025)06-1042-12

A Rapid Extraction Method of Summit Point for Emergency Communication System Siting Based on Enhanced Convolutional Neural Network

ZHEN Jie[1]　*QI Junjie*[1,2]　*WANG Yong*[1]　*XU Shenghua*[1]　*LIU Jiping*[1]

1　Chinese Academy of Surveying and Mapping, Beijing 100036, China

2　School of Geomatics, Liaoning Technology University, Fuxin 123000, China

Abstract: **Objectives**: It is urgent to solve the problem of rapid construction and optimal deployment of emergency communication network when large-scale natural disaster occurs. **Methods**: First, the peak points feature dataset is built up by fusing the digital elevation model with contour, slope, and slope aspect to improve the feature information of the peak area. Then, the screening conditions of the peak area for emergency communication are given and an enhanced faster region-based convolutional neural network (Faster R-CNN) is proposed to adapted to the multi-scale positioning of the peak area. Finally, we split, detect, and then merge the large area to improve the recognition effect of the peak area, and use the local maximum value method to achieve the precise extraction of peak points for emergency communication. **Results**: Comparing the proposed improved algorithm with other algorithms, the mean average precision (mAP) reaches 94.92%, the accuracy of peak points extraction reaches 94.2%, the effective coverage rate of the communication node reaches 80.56%, and the visibility rate reaches 77.43%. **Conclusions**: The proposed method is effective in identifying small targets, more in line with the terrain characteristics than other methods, and meets the actual communication needs in terms of communication to achieve a larger coverage. The extraction results of the proposed method can be used as a reference for the deployment of emer-

基金项目:国家重点研发计划(2022YFC3005705)。

第一作者:甄杰,博士,研究员,研究方向为室内外一体化导航定位、应急通信等。zhenjie@casm.ac.cn

通信作者:刘纪平,博士,研究员。liujp@casm.ac.cn

gency communication nodes to help complete the optimization of the deployment of communication nodes for emergency rescue, and to protect the regional communication smooth.

Key words: convolutional neural network; emergency communication system siting; summit point extraction; signal coverage; viewshed analysis

在地震、泥石流、洪水和森林火灾等重特大自然灾害发生时,道路、电力和通信往往遭到严重破坏形成“三断”情况,受灾区域会形成信息孤岛[1],严重阻碍应急救援通信指挥决策。在公共通信网络中断时,应急通信保障部门的首要任务是快速选择适合的地点作为临时通信节点,派遣通信力量快速到达指定地点并搭建应急通信网络,保障现场与后方的通信畅通。为了获得较好的信号传播条件和尽量大的信号覆盖区域,通常选择地势较高并且易到达的山顶区域布设通信节点。但是如何筛选易到达、易架设的山顶点,并且通过优化算法选择达到预定通信覆盖率和通信质量的最优通信节点数量等是应急通信指挥调度人员首先需要考虑的问题之一。目前中国省、市、县各级通信保障队伍的现场指挥员普遍缺乏基于高精度数字地形数据和人工智能结合的筛选手段进行应急现场通信节点的选址分析和决策。

数字地形特征要素是反映地貌形态的空间分布的矢量要素,点、线、面三要素构成了反映真实地貌空间形态的基本框架。地形特征点主要包括山顶点、裂点、径流节点、沟头点、鞍部点等[2]。地形特征点能够直接反映出该位置的地形信息与地貌特征,同时还蕴含着该位置周围的地貌变化信息。其中,山顶点是最具代表性与控制性的地形特征点之一,主要体现为局部区域内的高程极大值位置点[3]。山顶点通常四周开阔、具有良好的信号传播条件,在满足易到达、易部署的前提下,可作为优选的通信节点布设位置,增强信号覆盖率和通信质量。

实际提取山顶点时可能存在模糊性,并且提取精度与高程、坡度、区域范围联系紧密,在地貌特征复杂、地势起伏较大的环境中,山顶点难以精确量化。因此,针对山顶点的提取与分析,学者们以数字高程模型(digital elevation model, DEM)为数据基础提出了解决方法,主要从地表水流模拟分析[4]、断面高程极值[5-6]、邻域分析[7]、几何形态特征分析[8-9]、正反地形提取分析[10]等5个方面开展研究。文献[3]整体提取分析结果较好,但其设置参数过多,效率偏低,对平坦区域分析较弱。文献[5]对常用的断面高程极值方法进行了改进,提出特征显著度进行结果修正,提高抗噪能力。文献[6]重点讨论了DEM的分辨率以及邻域分析窗口大小,一定程度上依赖于窗口大小,无法实现定量化。文献[7]通过采用封闭等高线设置最大起伏度阈值,但依然存在伪山顶点和山顶点丢失情况,阈值的主观性影响了提取结果。文献[8]提出通过确定山体范围并利用坡向特征提取山顶点,但依然存在山体范围主观性、约束条件不够明确的情况。文献[10]首次提出反地形DEM概念,山顶区域反转为汇水区域,利用水文分析计算汇水中心从而提取山顶点。文献[11]提出了一种结合热点分析聚类和改进的八连通提取算法,能够克服低精度和虚假山顶点等局限性,快速准确地提供了山顶点的位置与高程。

栅格数据格式与神经网络所用数据结构存在相似性,但其本身连续变化的特点使得山顶区域的特征并不突出,直接使用DEM作为卷积神经网络(convolutional neural network, CNN)的基础数据提取山顶点将产生极大的困难。因此,本文将使用DEM为基础数据,设计一种新的数据集,通过采用等高线和坡面、坡向融合的方式制作山顶点特征数据集,提高DEM山顶区域的特征信息,给出适合应急通信节点的山顶区域筛选条件,提出增强更快速区域卷积神经网络(faster region-based convolutional neural networks, Faster R-CNN)算法模型完成山顶区域的快速定位,运用局部极大值方法完成山顶点的精确化提取,为重特大自然灾害情况下的应急通信网络快速搭建和高质量通信保障提供技术支持。

1　研究区概况

本文研究区域聚焦于四川省雅安市宝兴县及其周边20 km辐射范围,地理坐标为102°41′E～102°54′E,30°18′N～30°29′N,地处四川盆地西缘向青藏高原过渡的关键部位,隶属龙门山构造带中南段。在地貌特征上,研究区属典型的高山峡谷地貌区,呈现强烈的地形切割特征,海拔806～3 278 m,最大相对高差达2 472 m,地形坡度多超过35°。该地区发育有典型的地震-滑

坡-泥石流灾害链,具有灾害类型齐全、成生关联性强、复发周期短等特点。以该区域作为研究对象具有典型性,可为同类型地貌区的应急通信山顶点提取提供实证参考。研究区概况如图1所示。

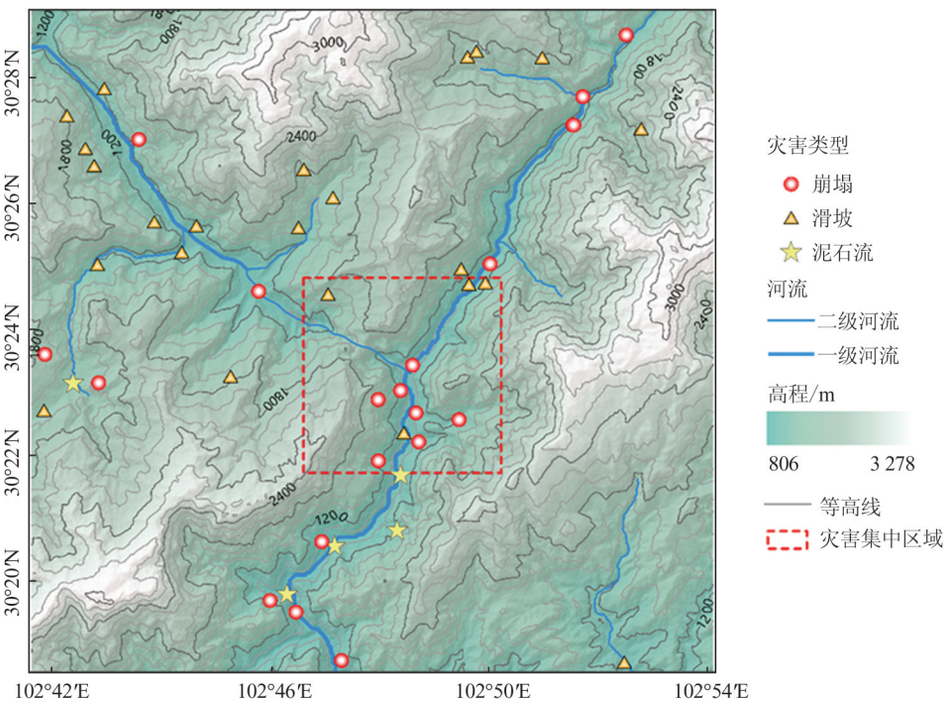


图1 研究区概况

Fig. 1 Overview of the Study Area

2 应急通信山顶点特征数据集

2.1 特征数据集构建

DEM数据与传统图像数据的格式具有相似性,将栅格单位对应像素单位、高程值对应像素值,就可以采用图像处理方法对DEM数据进行处理,图像数据为三波段格式,能够突出表达图像内容特征,而DEM数据的栅格属性只表达高程值,特征信息不够突出,难以进行精确目标检测。在同一等高线上的点高程值相同,且每条等高线间的高差相同,山顶区域在等高线数据中表现为最大封闭等高线,内部再没有其他等高线,且高程值高于周围等高线;坡度是DEM数据内一定区域高程值变化比率的量度,通常使用0°~90°表示,山顶区域边缘坡度较大,而内部区域坡度逐渐变小;坡向表示该区域高程值改变量最大的方向,使用0°~360°范围重分类表示8个地理方向,山顶区域为坡向变化最丰富的区域[12]。为了丰富地形特征,本文采用高程、等高线、坡度、坡向数据融合构建山顶点特征数据集。

高程值直接反映一定地形特征,不需要处理。将等高线数据格式由矢量转换为栅格格式,以栅格为单位保留等高线闭合、连通的数据特征。坡向0°~360°范围重分类代表8个地理方向,并将坡向数据融合到栅格等高线数据中,将山顶区域地形变化可视保留,丰富地形特征。对高程、等高线、坡度进行极大极小标准化,将其映射到[0,255]内,映射情况如表1所示。将标准化数据进行波段融合得到山顶点特征数据,山顶点特征数据制作流程如图2所示。

表1 数据分类映射

Table 1 Data Classification Mapping

数据	映射前	映射后
坡向/(°)	−1~22.5	1(北)
	22.5~67.5	2(东北)
	67.5~112.5	3(东)
	112.5~157.5	4(东南)
	157.5~202.5	5(南)
	202.5~247.5	6(西南)
	247.5~292.5	7(西)
	292.5~337.5	8(西北)
	337.5~360	1(北)
高程/m	1 971~5 914	0~255
等高线/m	2 000~5 800	0~255
坡度/(°)	0~90	0~255

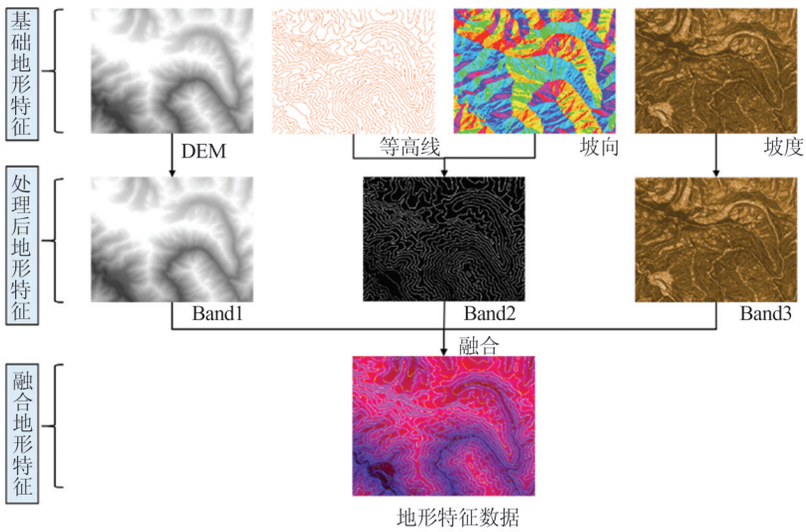


图 2　山顶点特征数据制作流程

Fig. 2　Production Process of Peak Points Feature Data

2.2　山顶点筛选条件

为保证四川高山峡谷地貌区的应急通信,通常选择无遮挡且满足一定信号覆盖条件的山顶点作为应急通信节点的候选点。但是山顶点是难以精确量化的地理对象,局部区域内的高程极大值位置点并不一定都是山顶点,并且只有少部分山顶点地形遮蔽条件良好,可作为应急通信节点的候选点。

典型二维化山顶点如图 3 所示。其中,H 表示海拔,S 表示距离,ΔH、ΔS 分别表示高差和距离差,A~F 分别表示不同特点的山顶点。分析可知,点 A 为面积较大的高原或面积较小的平台与断崖的交界处,山体一侧利于信号传播,但容易被忽视;点 B、C 为高处山顶点,点 C 高程较高,但存在如点 B 位于山脊线上的点,ΔH 与 ΔS 过小,易对点 C 造成干扰,可通过高差与距离差进行过滤;点 D、E 为较低高程山顶点,多为山谷内或集水区内的局部凸起,ΔH 与 ΔS 过小,不利于信号传播,可通过高差与坡度进行过滤;点 F 四周遮挡较少,利于信号传播。保留点 A、C、F 类似山顶点,过滤点 B、D、E 类似山顶点,结合特征数据集,本文给出山顶区域筛选条件如下:

1)位于区域最大封闭等高线上及内部;

2)封闭等高线内部区域高程大于或等于封闭等高线上区域;

3)封闭等高线上及内部存在坡度为 0°~10° 或 80°~90° 区域,同时封闭等高线附近形成坡度突变带,坡度变率提高,由边缘到核心坡度渐小;

4)封闭等高线内部存在一个或多个区域坡向呈放射状分布,即分类映射后 1~8 代表 8 个地理方向,坡向值沿顺时针方向呈明显递增趋势。

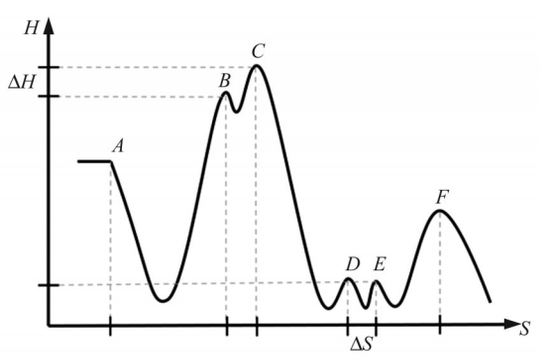


图 3　典型二维化山顶点示意图

Fig. 3　Diagram of Peak Points of Typical 2D Mountains

2.3　样本数据集构建

使用应急通信山顶点特征数据集制作样本数据集。将特征数据裁剪成大小相同的矩形数据,通过软件辅助人工标绘的方式,根据以上山顶区域筛选条件对数据中存在的山顶区域进行框选,以最大封闭等高线外侧边缘为基准,在保留有效特征信息的同时减少无效信息干扰,保存标注框左上角和右下角的像素坐标分别为(x_{min},y_{min})、(x_{max},y_{max}),保证数据与标签一一对应,形成模型训练用样本数据集。

3　研究方法

3.1　总体框架

首先使用DEM与相关数据融合的方法制作山顶点特征数据集,提高山顶区域特征信息,分析满足应急通信山顶区域筛选条件;然后通过融

合特征提取网络与特征金字塔网络,提出能够面向应急通信节点并适应多尺度山顶区域定位的增强Faster R-CNN算法模型,针对大区域进行拆分检测后合并,提高定位识别效果,运用局部极大值提取山顶点,完成对大、小范围区域山顶点的快速提取;最后对模型进行评估,并对提取结果、信号覆盖情况进行对比分析。总体架构如图4所示,主要包括:

1)特征数据集构建与提取。通过DEM数据获取等高线、坡度、坡向数据,统一量纲后,将特征数据进行通道融合,制作山顶点特征数据集。分析满足应急通信的山顶区域特征,总结山顶区域筛选条件,制作标签形成样本数据集。

2)区域定位模型构建与训练。设计增强Faster R-CNN算法模型,融合特征提取网络和特征金字塔网络,使用交并比(intersection over union, IoU)、锚框、非极大值抑制(non-maximum suppression,NMS),利用训练数据集对模型进行特征识别训练,得到能够面向应急通信节点并适应多尺度山顶区域定位的增强Faster R-CNN算法模型。

3)山顶点识别与提取。通过模型对山顶区域进行识别,针对识别范围分为大、小区域,对识别数据进行裁剪、标识、合并等操作提高识别精度,将山顶区域转化为山顶点。

4)结果分析评价。采用损失值L、准确率A、精确率P、召回率R、$F1$分数、均值平均精度(mean average precision,mAP)等评价指标进行对比分析,判断增强模型优劣,并将整体方法在山顶点提取结果与信号覆盖情况进行对比分析。

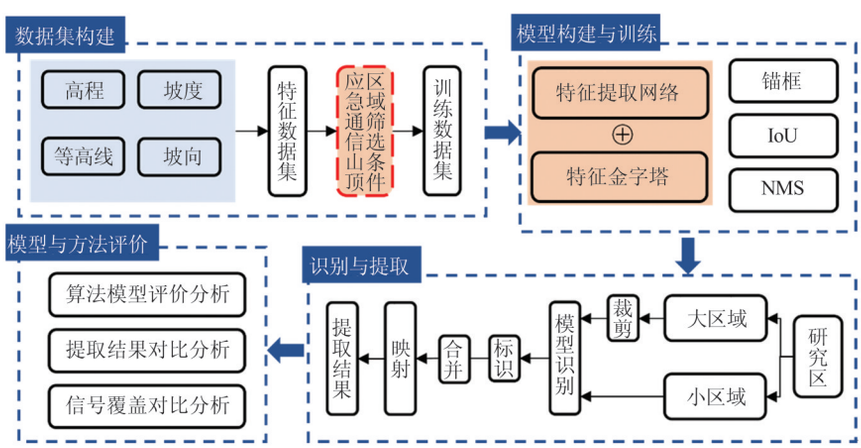


图4 本文方法总体架构图

Fig. 4 Overall Architecture of the Proposed Method

3.2 增强Faster R-CNN算法原理

CNN[13]经过区域CNN算法(region-based CNN,R-CNN)[14]和Fast R-CNN算法[15]的发展,文献[16]提出了Faster R-CNN算法,引入区域候选网络(region proposal network,RPN),利用提取边缘神经网络代替之前的选择性区域搜索,综合性得到较大提升。Faster R-CNN算法通过特征提取网络提取特征图,经过RPN判断特征区域并修正锚框,从而生成精确候选区域。但由于Faster R-CNN对本文的山顶区域特征识别较弱,小目标及复杂区域难以识别,为了使其在地形特征数据集中能有效识别特征信息,完成对山顶区域的精确定位,本文提出了增强Faster R-CNN算法,其流程如图5所示。

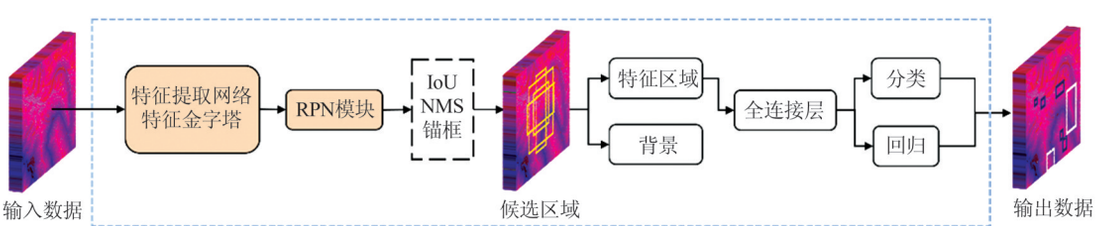


图5 增强Faster R-CNN算法流程图

Fig. 5 Flowchart of Enhanced Faster R-CNN Algorithm

增强Faster R-CNN算法对Faster R-CNN算法进行的改进如下:

1)特征提取网络选用ResNeSt。特征提取网络有传统的视觉几何组[17](visual geometry group, VGG)和残差网络[18](residual network, ResNet)等,而受ResNeXt、SENet和SKNet的启发,分离注意力网络[19](split-attention networks, ResNeSt)使用分离注意力模块将特征图分离为几个组,每组的特征通过分离表示的加权组合确定和表示,通过多个模块组合从而形成网络。本文的地形特征数据集为多通道数据,并且含有大量代表地形特征的信息,通道信息之间相互影响,ResNeSt网络保留学习深度并且能够实现跨通道特征交流,比VGG和ResNet网络更能深层次挖掘地形特征。

2)特征提取网络融合。特征金字塔网络(feature pyramid networks, FPN)[20]是针对目标检测提出的一种检测多尺度网络,在不提升计算量的前提下,增加检测小目标的能力。本文数据集存在大量尺寸为10×10的山顶区域,小目标所包含的特征信息较少,易被特征提取网络忽略。在特征提取网络ResNeSt中融合FPN,FPN将所有层的特征保留,将特征由上至下进行侧边连接,同时进行横向连接,将高层的特征进行上采样内插值,使各层特征大小相同,再将其与前一层特征进行连接,保证所有尺度的特征都具有良好的几何信息和语义信息。网络结构如图6所示。

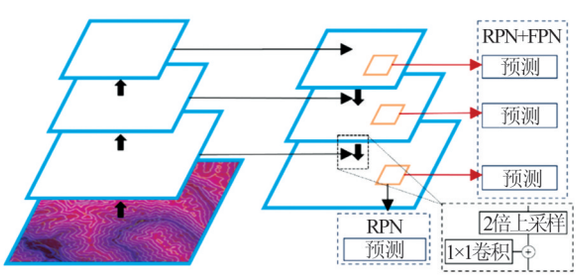


图6　FPN模型结构

Fig. 6　Structure of FPN Model

由于使用的特征图由单层变成了多层,结合ResNeSt网络中的感兴趣区域(region of interest, ROI)Pooling层就需要相应变化,对不同层的特征使用不同的ROI尺度。大尺度ROI使用深层特征作为输入,小尺度ROI使用浅层特征作为输入,定义P_k系数作为判断依据,计算式为:

$$\mathrm{int}(P_k)=\left[k_0+\log_2\left(\sqrt{\omega h}/256\right)\right] \tag{1}$$

式中,k_0为基准值,设为5表示原图大小使用第5层特征;ω和h分别是ROI的长和宽;256是数据集图片输入尺寸。假设ROI大小为100×100,$\mathrm{int}(P_k)=5-1=4$,表示此ROI应该使用第4层特征。

3)锚框大小确定。原始RPN网络设置9个锚框为初始检测框,锚框大小分别为128、256、512,长宽比分别为1:1、1:2、2:1,初始大小设置不能完全符合不同的特征数据集,因此本文使用二阶聚类对特征数据集中的锚框进行聚类分析。二阶聚类能够对大样本的连续变量和分类变量进行聚类,能够自动确定类别数量,避免欧氏距离对于离散点敏感造成聚类效果不理想的问题,最后将聚类结果作为锚框初始参数设置。

4)IoU。生成的锚框并不一定全部准确,因此需要引入IoU来对所有锚框进行筛选。IoU参数设置将会对训练结果造成影响,本文使用IoU>0.7标记为正样本锚框,IoU<0.3标记为负样本锚框,介于两者之间的样本为难例,为了提高模型质量,不参与训练。IoU值计算式如下:

$$I_{\mathrm{IoU}}=\frac{A_{\mathrm{anchor}}\cap B_{\mathrm{anchor}}}{A_{\mathrm{anchor}}\cup B_{\mathrm{anchor}}} \tag{2}$$

式中,A_{anchor}为预测锚框面积;B_{anchor}为实际锚框面积。

5)NMS。NMS的思想是找到局部置信度的极大值,筛选局部周围的多余锚框,从而获得清晰的目标位置。在本数据集中的作用是寻找同一区域内相同类别的区域,保留置信度更高的区域,如果NMS设置的较高,相邻的区域将会只有一个保留下来。随后再次对锚框进行回归计算,计算锚框坐标与真实锚框坐标的偏移量,对锚框位置进行微调,如图7所示。

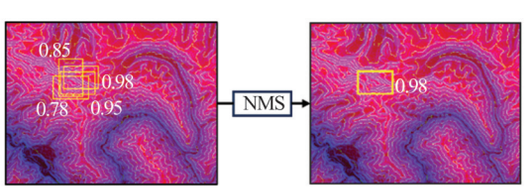


图7　非极大值抑制

Fig. 7　Non-Maximum Suppression

6)预训练权重与冻结训练提高模型泛化能力。将预训练权重主要参数结构进行网络结构相应修改,使用冻结训练和解冻训练进行预训练,先冻结不修改权重参数学习特征,再解冻进行参数微调,获得属于本文特征数据集的训练权重[21]。预训练结束后进行特征数据集的正式训

练,提高识别训练效率,从而提高识别精度。

3.3 山顶点提取

使用训练后的模型对研究区域进行预测,研究区域尺寸与训练数据尺寸相同或小于时为小区域,反之为大区域,小区域可直接预测和提取,大区域与训练数据尺寸相差过大时直接预测效果并不理想,为了能使其预测与提取效果更加精确,本文以大区域为例,展现其处理方法。

使用滑动窗口将大区域裁剪成与训练时数据相同尺寸的小区域分别预测。在预测过程中存在部分山顶区域被裁剪分开的情况:(1)分开各部分均被识别成山顶点;(2)分开各部分均未被识别成山顶点。在所有区域预测完成后进行坐标转换与合并,形成大区域预测结果,并针对以上两种错误情况分别进行合并与标识,如图8所示。得到大区域的正确山顶区域预测框后,将标框映射到原始DEM数据中,运用局部极大值方法计算标框内区域的高程矩阵,进行山顶点提取,并记录山顶点坐标,最终得到区域内的山顶点集合,流程图如图9所示。区域内高程最大值计算如下:

$$Z_{(i,j)}=\mathrm{MAX}\left(\begin{bmatrix} Z_{11} & \cdots & Z_{1j} \\ \vdots & \ddots & \vdots \\ Z_{i1} & \cdots & Z_{ij} \end{bmatrix}\right) \tag{3}$$

式中,$Z_{(i,j)}$为区域内高程最大值,即山顶点;Z_{ij}为$i\times j$范围内某坐标下的高程值。

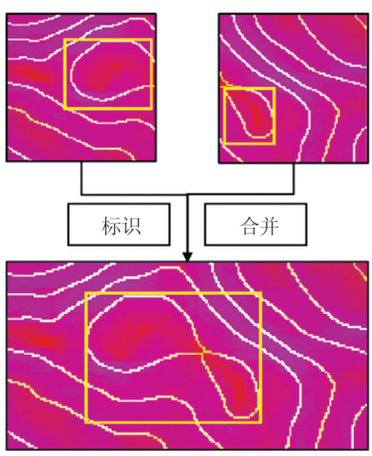


图8 大区域处理

Fig. 8 Large Area Treatment

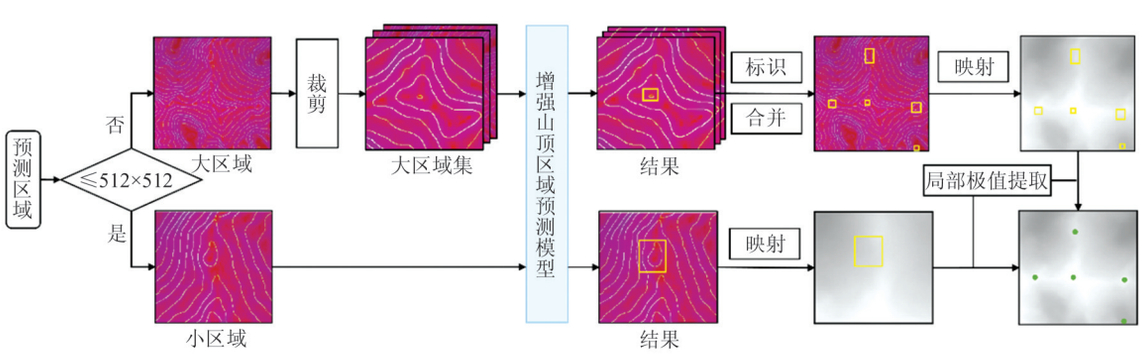


图9 山顶点提取流程图

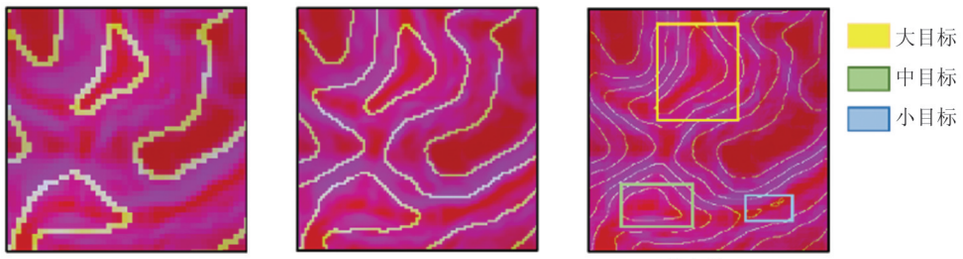
Fig. 9 Flowchart of Peak Points Extraction

4 实验与分析

4.1 实验环境与参数设置

训练用样本特征数据集使用四川省及周边山区DEM数据,数据源自地理空间数据云发布的ASTER GDEM V3数据集(http://www.gscloud.cn),初始数据为30 m分辨率,通过插值算法分别生成20 m和10 m分辨率数据,并生成200 m、100 m、50 m的等高线数据,通过制作不同分辨率和等高距进行对比分析,结果如图10所示。图10(a)使用30 m分辨率和200 m等高距时山顶区域边界模糊,损失较多细节特征;经过图10(b)的改进后,细节更为丰富;最终使用图10(c)中的10 m分辨率和50 m等高距,细节特征最为丰富,区域边界更加准确具体,并能够明显区分大、中、小3种山顶区域。使用滑动窗口将DEM数据裁剪为512×512尺寸栅格数据制作数据集,裁剪区域重叠度为20%。如果裁剪尺寸不满足512×512,则使用填补灰条的方式使其满足条件,共计1 504张。

预测使用四川省雅安地区20 km山区DEM数据,因预测范围较大,使用滑动窗口将DEM数据同样处理为512×512栅格,对小区域分别进行预测,得到带有预测山顶区域的结果后,根据像素坐标进行坐标转换,将预测山顶区域与小区域进行合并,得到整体预测区域预测情况。针对部分裁剪边缘的山顶点区域会被分开的情况,对裁剪边缘进行检查,如果存在山顶点区域,将不计入对比分析中。



(a) 等高线: 200 m
分辨率: 30 m×30 m　　(b) 等高线: 100 m
分辨率: 20 m×20 m　　(c) 等高线: 50 m
分辨率: 10 m×10 m

图 10　不同分辨率和等高距数据对比图

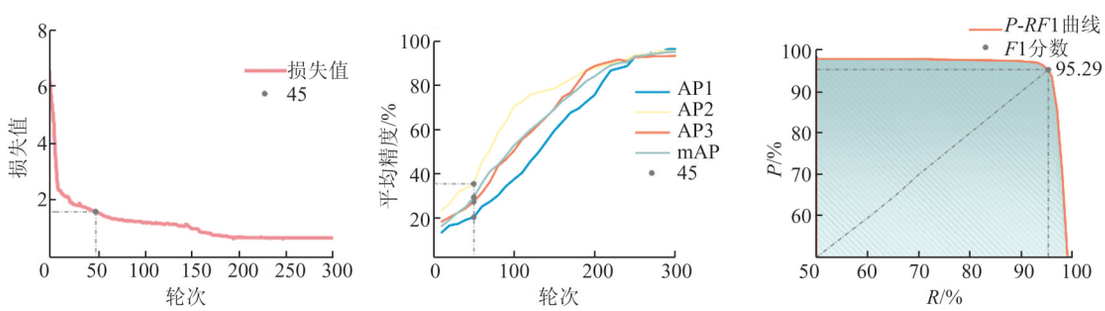
Fig. 10　Comparison of Data at Different Resolutions and Contours

模型运行硬件环境为 Windows 10 操作系统，使用显卡 NVIDIA GeForce GTX 4060Ti 16 GB，运行内存 32 GB，CPU 为 Intel i5 13600kf，编程框架采用 Python＋Pytorch-GPU。模型采用动态调整学习率的方式，范围是[0.000 1,0.01]。预训练迭代次数共 300 次，其中冻结训练 50 次，解冻训练 250 次。锚框设置尺寸通过聚类分析共获得 3 类结果，将锚框尺寸设置为 27.16×26.95、40.25×40.4、85.5×86.4 共 3 种尺寸，最后得到 9 个初始锚框。RPN 模块中特征提取网络选择 ResNeSt＋FPN 模型。

4.2　模型评估

训练结束并预测成功后，为了探究改进方法的提升，将在原始 Faster R-CNN 算法下使用的 VGG 模型、ResNet 模型和改进 ResNeSt 模型、改进 ResNeSt＋FPN 模型进行对比分析。本文识别结果只有山顶区域和非山顶区域两个类别，对所有识别结果按 3 个锚框大小的面积分为小、中、大目标 3 类，分别为 AP1、AP2、AP3，通过计算 mAP 与 $F1$ 分数来衡量增强模型的性能。

对本文提出的增强方法进行训练和预测后的情况如图 11 所示，包括损失曲线、mAP 曲线和精确率-召回率(P-R)曲线。



(a) 损失曲线　　(b) mAP曲线　　(c) P-R曲线

图 11　模型训练与预测情况

Fig. 11　Model Training and Prediction Status

由图 11(a)可以看出，损失曲线平稳下降，展示出模型训练过程中性能稳定提升，没有出现过拟合现象，在迭代 200 次之后开始趋于稳定，模型能够捕捉到训练集中的特征规律。由图 11(b)可以看出，迭代 300 次之后 mAP 达到了 94.92%；由于本文特征数据集中小目标区域较多，难于识别或易于混淆，针对小目标处理后的增强模型仍需要较多代训练，最终小目标(AP1)的 mAP 达到了 96.17%，略高于中目标(AP2)的 95.4% 和大目标(AP3)的 93.17%，取得了较好的效果；中目标大小适中，相较于小、大目标更易于识别，训练较快；大目标区域形状复杂，有大量背景特征，识别精度相对较低。

以 Faster R-CNN 算法为基础，分别采用 VGG 模型、ResNet 模型、ResNeSt 模型与本文改进的 ResNeSt＋FPN 模型进行对比，结果见表 2，其中精确率主要展示小目标精确率。

通过对比实验可得，准确率、精确率、召回率、$F1$ 分数均有提升，3 类目标区域的 mAP 达到了 94.92%，本文增强 Faster R-CNN 算法相较于其他算法能够更加精确识别山顶点区域。

ResNeSt 模型的改进使得训练速度从 7.2 h 缩短至 6.8 h，大幅减少了训练所需时间，并在准确率与精确率上分别提升至 89.74% 和 92.32%，

分别提升了5.17%和1.61%,提升较大,说明模型能够有效识别到区域特征,随后改进再融合FPN模型,因为需要融合计算多层特征,从而导致模型计算时间较长,但它提高了小目标的特征层分辨率,使得模型在检测小目标上取得了较高的精确度,由92.32%提升至96.17%,从而使得模型整体能够精确识别潜在山顶区域位置。

表2 不同模型指标对比

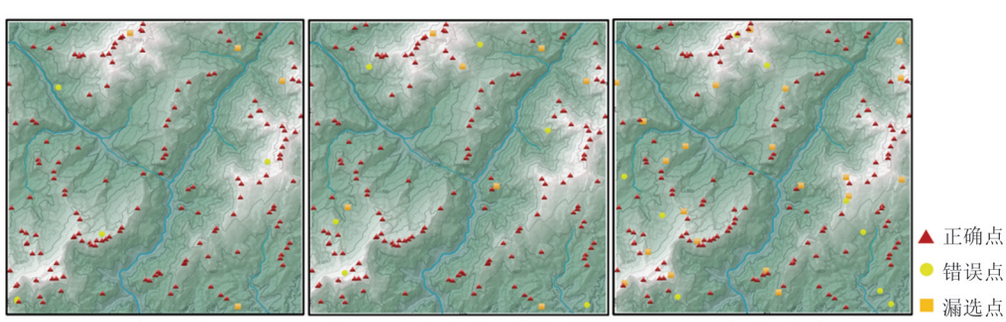
Table 2 Index Comparison of Different Models

模型	训练用时	预测用时/(张·s^{-1})	模型大小/MB	准确率/%	精确率/%	召回率/%	F1分数/%	mAP/%
VGG	7	1.35	109	82.86	89.87	87.65	88.75	86.23
ResNet	7.2	1.32	129	84.57	90.71	89.14	89.92	87.84
ResNeSt	6.8	1.25	201	89.74	92.32	91.36	91.83	91.43
ResNeSt+FPN	8	1.31	308	93.42	96.17	94.76	95.29	94.92

4.3 山顶点提取结果分析

使用本文提出的增强模型对研究区进行潜在山顶点区域识别,再对结果区域进行提取获得山顶点,为验证本文山顶点提取方法的准确性,对研究区域分别使用正反地形法、传统邻域分析法进行山顶点提取实验,提取结果如图12所示,结果分析统计见表3。

由图12和表3可知,本文方法与正反地形法、传统邻域分析法的提取准确率分别为94.2%、91.8%、84.2%,3种方法的错误数相差不多,但本文方法遗漏山顶点明显少于其他方法。传统邻域分析法提取结果较多,不同区域地形下设置不同邻域范围值对提取结果影响较大,部分区域产生冗余山顶或遗漏山顶点,导致准确率较低。正反地形法提取结果准确率有所提高,一定程度上克服了阈值的不确定性,但其操作流程较为复杂。本文方法提取结果明显提高,克服了遗漏山顶点问题,准确率较高,更加符合区域的地形特征。



(a) 本文方法 (b) 正反地形法 (c) 邻域分析法

图12 山顶点提取结果对比

Fig. 12 Comparison of Peak Points Extraction Results

表3 山顶点提取结果统计

Table 3 Statistics of Peak Points Extraction Results

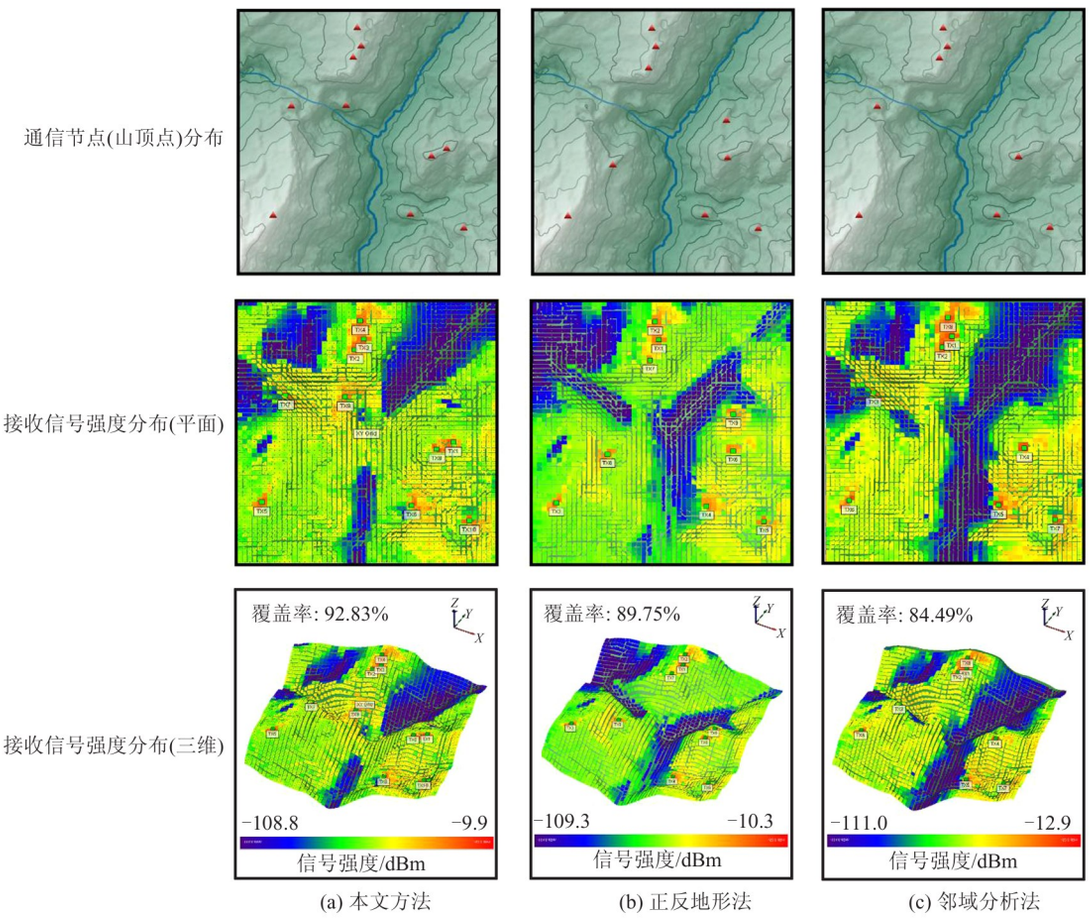
提取方法	总数/个	正确数/个	错误数/个	遗漏数/个	准确率/%
本文方法	155	146	5	4	94.2
正反地形法	158	145	6	7	91.8
邻域分析法	190	160	9	21	84.2

4.4 信号覆盖情况分析

将3种方法在图1所示的灾害集中区6 km×6 km范围内提取的山顶点作为选定通信节点,采用美国Wireless Insite(WI)信号传输与特性仿真软件[22]分别进行信号覆盖模拟分析,地形数据采用GDAL Terrain格式数据。假定通信节点信号发射功率为10 W,信号频率为1.4 GHz,带宽为20 MHz,天线高为1 m,采用全向天线,接收机灵敏度为-103 dBm,每100 m网格模拟部署一个接收机接收信号,信号覆盖情况如图13所示。

图13中信号强度-103 dBm以上为有效接收信号,针对同一灾害集中区域,本文方法信号有效覆盖达到92.83%,在3种方法中效果最优,可有效覆盖高、中、低海拔不同区域。正反地形法信号有效覆盖为89.75%,在灾害集中区存在信号覆盖较差的情况。邻域分析法的信号有效覆盖为84.49%,在3种方法中信号有效覆盖最低,存在较大范围无信号覆盖的区域。

为进一步对比3种方法提取的山顶点信号覆



(a) 本文方法　　(b) 正反地形法　　(c) 邻域分析法

图 13　信号覆盖情况对比

Fig. 13　Comparison of Signal Coverage

盖效果,采用 ArcGIS pro 软件辅助优化选址的遗传算法,将适应度目标函数替换为可视率达到最大,优化节点数设置为 5 个,计算 3 种方法在灾害集中区域的可视域覆盖情况,如图 14 所示。

由图 14 的可视域覆盖情况对比可知,在灾害集中区 3 种方法均采用 5 个节点数的情况下,本文方法有效覆盖情况依旧表现良好,单节点最大可视率达到 30.60%,整体可视率达到 77.43%,在 1 号和 5 号节点处可视面积均为最大。正反地形法和邻域分析法的可视率分别为 72.79% 和 71.03%,均小于本文方法。

综合对比信号覆盖和可视域的结果表明,本文所提的增强 Faster R-CNN 算法提取的应急通信山顶点信号有效覆盖范围大,覆盖范围均匀,在灾害发生地附近信号覆盖情况最优,部分地区能够覆盖到可能存在居民点的低海拔区域。

5　结　语

本文通过 DEM 数据、等高线和坡度、坡向融合的方法制作山顶点特征数据集,给出应急通信山顶区域筛选条件,并提出增强 Faster R-CNN 算法及后处理方法能够在融合数据上进行山顶点区域的有效定位,再进行山顶点精确化提取并获得山顶点实际坐标值。通过评价指标对模型进行综合评估,本文增强方法能够完成多种尺度的区域识别,mAP 达到了 94.92%,能够快速提取潜在山顶区域,在识别小目标上效果显著。在山顶点提取结果上准确率达到了 94.2%,较其他方法更加符合地形特征。针对山顶点在应急通信节点选取中的表现,分别进行信号覆盖对比与可视域覆盖对比,覆盖率分别达到了 92.83% 和 77.43%.结果表明,结合地形特征与应急通信特点的筛选条件能够有效提取出符合地形特征与应急通信的山顶点,为应急通信节点选址提供部署支持。

地形特征要素除山顶点外,还包括山脊线、山谷线等重要地形特征要素,未来研究将考虑多种地形特征的快读提取,为应急通信网络规划和选址提供有力的技术支持。

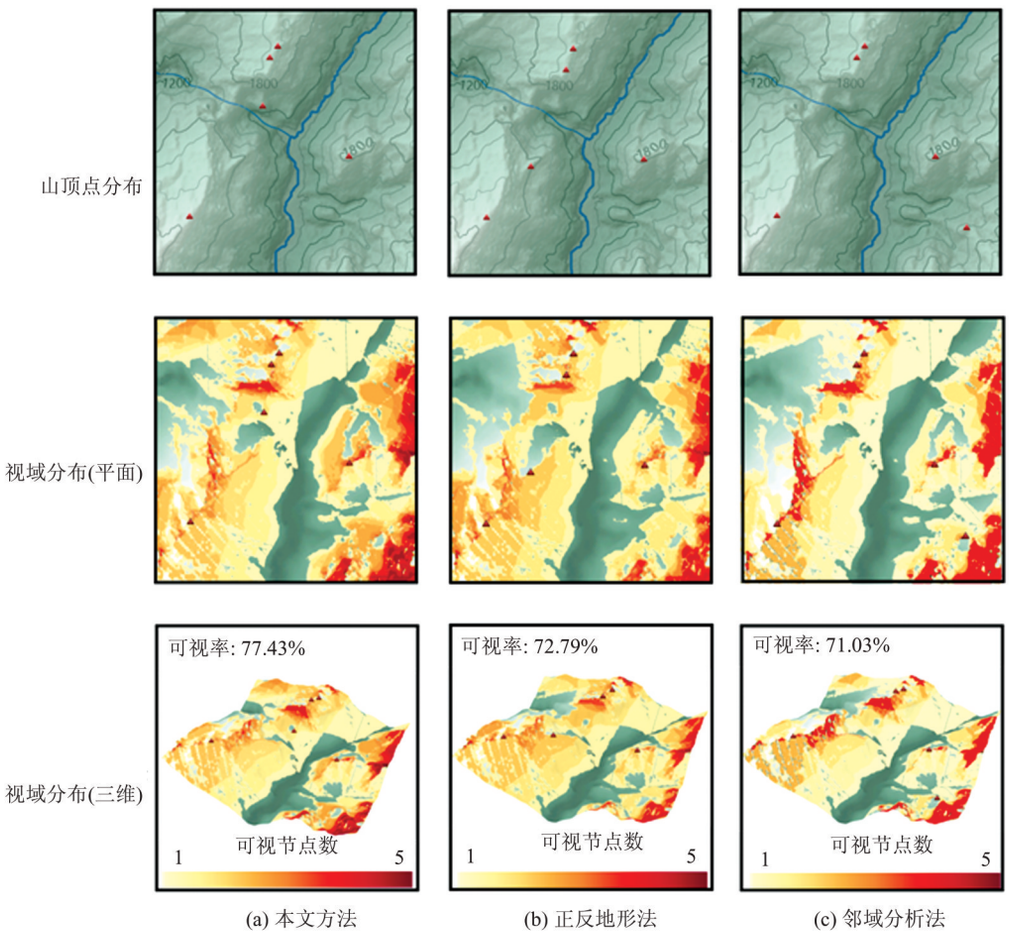


图14 可视域覆盖情况对比

Fig. 14 Comparison of Visual Field Coverage

参 考 文 献

[1] 王彩平, 刘钊. 重大自然灾害应急指挥协调信息沟通[J]. 理论与改革, 2016, (5): 10-12.
WANG Caiping, LIU Zhao. Major Natural Disasters Emergency Command Coordination Information Communication [J]. *Theory and Reform*, 2016, (5): 10-12.

[2] 汤国安. 我国数字高程模型与数字地形分析研究进展[J]. 地理学报, 2014, 69(9): 1305-1325.
TANG Guoan. Progress of DEM and Digital Terrain Analysis in China[J]. *Acta Geographica Sinica*, 2014, 69(9): 1305-1325.

[3] 汤国安, 李发源, 刘学军. 数字高程模型教程[M]. 北京: 科学出版社, 2010.
TANG Guoan, LI Fayuan, LIU Xuejun. Course of Digital Elevation Model [M]. Beijing: Science Press, 2010.

[4] 郭万钦, 刘时银, 余蓬春, 等. 利用流域边界和坡向差自动提取山脊线[J]. 测绘科学, 2011, 36(6): 210-212.
GUO Wanqin, LIU Shiyin, YU Pengchun, et al. Automatic Extraction of Ridgelines Using on Drainage Boundaries and Aspect Difference [J]. *Science of Surveying and Mapping*, 2011, 36(6): 210-212.

[5] 黄培之, 刘泽慧. 地形断面高程极值法的理论研究[J]. 测绘通报, 2005 (4): 11-13.
HUANG Peizhi, LIU Zehui. Study of Extraction of Ridge and Valley from DEM Data[J]. *Bulletin of Surveying and Mapping*, 2005 (4): 11-13.

[6] 邹昆, 沃焱, 徐翔. 利用特征显著度提取地形特征线的方法[J]. 武汉大学学报(信息科学版), 2018, 43(3): 342-348.
ZOU Kun, WO Yan, XU Xiang. A Feature Significance-Based Method to Extract Terrain Feature Lines [J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(3): 342-348.

[7] 邹宝裕, 董丞妍, 苟娇娇, 等. 数字高程模型提取山顶点及空间格局差异[J]. 遥感信息, 2016, 31(2): 124-128.
ZOU Baoyu, DONG Chengyan, GOU Jiaojiao, et al. Extraction and Spatial Pattern of Landform Peaks Based on DEMs[J]. *Remote Sensing Information*, 2016, 31(2): 124-128.

[8] 顾留碗,王春,李鹏,等. 利用DEM提取山顶点精度研究[J]. 武汉大学学报(信息科学版),2016,41(1):131-135.
GU Liuwan, WANG Chun, LI Peng, et al. Research on Mountain Top Extraction Accuracy Based on DEM[J]. *Geomatics and Information Science of Wuhan University*, 2016, 41(1): 131-135.

[9] 周访滨,肖智文,刘学军,等. 栅格DEM山顶点提取的坡向分布特征法[J]. 武汉大学学报(信息科学版),2024,49(3):419-425.
ZHOU Fangbin, XIAO Zhiwen, LIU Xuejun, et al. Mountain Peak Extraction of Grid DEM Based on Aspect Distribution Feature[J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(3): 419-425.

[10] 仲腾,汤国安,周毅,等. 基于反地形DEM的山顶点自动提取[J]. 测绘通报,2009(4):35-37.
ZHONG Teng, TANG Guoan, ZHOU Yi, et al. Method of Extracting Surface Peaks Based on Reverse DEMs[J]. *Bulletin of Surveying and Mapping*, 2009(4): 35-37.

[11] ZHENG Z Q, XIAO X W, ZHONG Z C, et al. A Rapid and High-Precision Mountain Vertex Extraction Method Based on Hotspot Analysis Clustering and Improved Eight-Connected Extraction Algorithms for Digital Elevation Models[J]. *Remote Sensing*, 2021, 13(1): 81.

[12] 张福浩,朱月月,赵习枝,等. 地理因子支持下的滑坡隐患点空间分布特征及识别研究[J]. 武汉大学学报(信息科学版),2020,45(8):1233-1244.
ZHANG Fuhao, ZHU Yueyue, ZHAO Xizhi, et al. Spatial Distribution and Identification of Hidden Danger Points of Landslides Based on Geographical Factors[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(8): 1233-1244.

[13] FUKUSHIMA K. Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position[J]. *Biological Cybernetics*, 1980, 36(4): 193-202.

[14] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition, Columbus, USA, 2014.

[15] GIRSHICK R. Fast R-CNN[C]//IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015.

[16] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.

[17] SIMONYAN K, ZISSERMA A. Very Deep Convolutional Networks for Large-Scale Image Recognition[C]//The 3rd International Conference on Learning Representations, San Diego, USA, 2015.

[18] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016.

[19] ZHANG H, WU C R, ZHANG Z Y, et al. ResNeSt: Split-Attention Networks[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), New Orleans, USA, 2022.

[20] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature Pyramid Networks for Object Detection[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, USA, 2017.

[21] LIU H K, DING Q C, HU Z C, et al. Remote Sensing Image Vehicle Detection Based on Pre-training and Random-Initialized Fusion Network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 3508605.

[22] BOUSSAÏD I, LEPAGNOT J, SIARRY P. A Survey on Optimization Metaheuristics[J]. *Information Sciences*, 2013, 237: 82-117.