

DOI:10.13869/j.cnki.rswc.2023.05.015.

赵子林, 韩磊, 陈芮, 等. 基于深度学习的黄丘区正负地形分割[J]. 水土保持研究, 2023, 30(5): 21-30.

ZHAO Zilin, HAN Lei, CHEN Rui, et al. Positive and Negative Terrain Segmentation in the Loess Hilly and Gully Region Based on Deep Learning[J]. Research of Soil and Water Conservation, 2023, 30(5): 21-30.

基于深度学习的黄丘区正负地形分割

赵子林¹, 韩磊^{2,3}, 陈芮¹, 赵永华², 李亚北¹, 康宏亮²

(1. 长安大学 地球科学与资源学院, 西安 710054; 2. 长安大学 土地工程学院、陕西省土地整治重点实验室, 西安 710054; 3. 中国科学院 地球环境研究所黄土与第四纪地质国家重点实验室, 西安 710061)

摘要: [目的] 基于深度学习, 实现大范围、高精度的正负地形分割, 正负地形的有效分割对黄土高原水土流失治理及生态恢复重建具有重要的理论价值和指导意义。[方法] 在黄土高原丘陵区选取典型样区, 采用中分辨率 DEM 数据制作地形分割数据集, 构建了改进 Unet 的黄丘区正负地形分割模型, 该模型以 Unet 模型结构为基础, 引入残差模块替换卷积模块加深网络结构, 增加了地形信息的提取; 结合卷积注意力模块, 排除无用信息增加了模型抗干扰性; 优化激活函数与损失函数, 增强了模型鲁棒性与精度。[结果] 坡面畸变邻域判断法地形分割总体精度为 70.3%, 在深度学习模型中, 改进型 Unet 深度学习模型效果最优, 相较于 Unet 模型与 Res-Unet 模型都有一定的提升, 总体精度达到了 86.2%。[结论] 与传统的坡面畸变邻域判断法比较, 基于深度学习的网络模型分割结果精度评价指标均较优, 并验证了改进 Unet 的黄丘区正负地形分割模型的有效性。

关键词: 正负地形分割; 深度学习; Unet; 残差模块; 卷积注意力

中图分类号: P208

文献标识码: A

文章编号: 1005-3409(2023)05-0021-10

Positive and Negative Terrain Segmentation in the Loess Hilly and Gully Region Based on Deep Learning

ZHAO Zilin¹, HAN Lei^{2,3}, CHEN Rui¹, ZHAO Yonghua², LI Yabei¹, KANG Hongliang²

(1. School of Earth Sciences and Resources, Chang'an University, Xi'an 710054, China; 2. School of Land Engineering, Shaanxi Key Laboratory of Land consolidation, Chang'an University, Xi'an 710054, China; 3. State Key Laboratory of Loess and Quaternary Geology, Institute of Earth Environment, Chinese Academy of Sciences, Xi'an 710061, China)

Abstract: [Objective] Based on deep learning, a large-scale and high-precision positive and negative terrains segmentation is realized, and the effective segmentation of positive and negative terrains has important theoretical value and guiding significance for soil erosion control and ecological restoration and reconstruction in the Loess Plateau. [Methods] The typical sample area was selected in the hilly area of the Loess Plateau, and the terrain segmentation data set was made by using the medium resolution DEM data. The positive and negative terrains segmentation model of the improved Unet was constructed. Based on the Unet model structure, the residual module was introduced to replace the convolution module to deepen the network structure and increase the extraction of terrain information. Combined with the convolution attention module, eliminating useless information increased the anti-interference of the model; the activation function and loss function were optimized to enhance the robustness and accuracy of the model. [Results] The overall accuracy of the terrain segmentation of the slope deformation neighborhood judgment method is 70.3%. Among the deep learning models, the improved Unet model has the best effect, with a certain improvement compared with

收稿日期: 2022-10-13

修回日期: 2022-10-26

资助项目: 国家自然科学基金项目(41871190); 陕西省重点研发计划(2021SF-440); 黄土与第四纪地质国家重点实验室开放基金(SKLLQG2002); 长安大学中央高校基本科研业务费专项资金(300102353201)

第一作者: 赵子林(1995—), 男, 甘肃武威人, 硕士研究生, 主要从事土壤侵蚀、地形分析。E-mail: chdzhaozilin@163.com

通信作者: 韩磊(1979—), 男, 河南沈丘人, 博士, 副教授, 主要从事土壤侵蚀、污损土地修复、空间分析与建模。E-mail: hanshuanglei@chd.edu.cn

<http://stbcyj.paperonce.org>

both the Unet model and the Res-Unet model, and the overall accuracy reaches 86.2%. [Conclusion] Compared with the traditional slope distortion neighborhood judgment method, the accuracy evaluation index of the network model segmentation results based on deep learning is better, which verifies the effectiveness of the improved Unet model in terrain segmentation.

Keywords: positive and negative terrain segmentation; deep learning; Unet; residual block(RB); convolutional block attention module (CBAM)

黄土高原地形破碎,沟壑纵横,是全球水土流失最严重的地区之一^[1-2]。改善生态环境、防治水土流失、实现人与自然协调的社会经济可持续发展,已成为该区域的重大战略问题^[3-4]。地形地貌对区域生态环境及自然景观具有显著的制约作用^[5-7]。尽管黄土地貌类型表现复杂,但总体上可以分割为两类:正地形与负地形。作为黄土地貌分类的最基本的单元之一,正负地形是地形表达的重要基础,其土地侵蚀类型、植被覆盖和土地利用都存在着差异^[8-9]。因此,准确地划分正负地形,对黄土高原生态修复及土地利用规划具有重要的指导性意义和实际应用价值。

随着计算机技术在地理信息领域的深入发展与广泛结合,不少学者基于数字高程模型(DEM),对黄土高原正负地形进行分割提取,深入探究黄土高原地貌形成发育及演变,并取得了众多重大的成果^[10]。目前,基于 DEM 划分正负地形的思路主要有两种:地貌形态学分析法与图像分割法,基于此两种思路的地形分割研究逐渐成熟,提取算法也层出不穷。地貌形态学分析法是指在黄土高原地貌形态特征与侵蚀发育过程研究中,将基于高分辨率 DEM 建立起的形貌特征指标因子纳入到研究系统中,实现特征因子与地貌形态的关联关系,从因子特征分析方面,主要探索侵蚀沟谷、沟沿线以及正负地形所建立的指标因子之间关联关系^[11-16],但由于黄土高原地形复杂,地貌多样,区域间差异性较大,因此现有的算法自适应性较差,适用范围较小,且阈值选取时人为因素干扰严重,具有较大的主观性。基于图像分割方法以数字高程模型数据(DEM)为数据源,将其视为灰度图像,利用边缘检测^[17-20]、区域生长等^[21]图像分割算法提取沟沿线,对地形地貌进行分割,提取过程为全自动化或半自动化,减少了人为干预,但提取的特征较少,提取结果存在错分现象。

Unet 深度学习网络是 2015 年 Ronneberger 提出的一种对称型的网络结构,因其结构简单,所需数据量较少,被广泛应用于医学影像分割^[22]。近些年,计算机信息技术与遥感技术深度融合,越来越多的学者采用改进的 Unet 网络对遥感影像数据进行分割分类并取得了较好的效果。许玥^[23]通过加深 Unet

网络结构使其能表征更深层特征,并结合全连接条件随机场对分类图细化获取高精度水域分类图;卫佳杰^[24]利用 Unet 将双源数据——高分辨率遥感影像数据与 DSM 数据融合,得到区分性较强的特征,并引入卷积块注意力机制增加空间与通道信息,取得了较好的效果;徐佳伟等^[25]基于 Unet 网络,结合金字塔池化模块、残差模块与卷积块注意力构造深度学习网络对建筑物进行分割,取得了较高的精度。Cao 等^[26]将残差模块代替 Unet 的卷积层,并利用线性插值代替上采样中的反卷积层减少了模型参数及复杂度,提高了模型效率与精度;Hou 等^[27]提出了一种补充性 Unet 网络架构,该网络架构包含 4 个模块:标准的 Unet、阈值擦除、多尺度密集空洞卷积 Unet (MD-Unet)、融合,利用两次 Unet 网络依次分割后将两次结果融合,提高了图像分割的精度;Nagi 等^[28]综合利用卷积网络与卷积条件随机场的优点,并用残差模块(Res-Block)代替 Unet 网络中卷积层提出了 RUF 模型,在海洋浮冰分割中取得了很好的结果。

针对现有地形分割方法的不足,结合深度学习网络在图形分割中呈现出的自适应性强、自主学习目标特征、全自动化等优点,本文将构建一个改进型的 Unet 深度学习模型应用于地形分割中,该模型利用残差模块替代原本的卷积层,加深原有的网络深度,并对激活函数与损失函数优化,选取性能较优的 H-Swish 激活函数和 Focal 损失函数组合,最后增加注意力机制模块,配置不同通道的权重,提高地形分割的精度。经过改进的 Unet 的网络模型使网络性能更高效,适用范围更广,可以有效划分大面积正负地形。

1 研究区及数据概况

1.1 研究区概况

本文研究区位于黄土高原腹部的陕西省延安市吴起县内。吴起县地势复杂,大体上为“八川二涧两大山区”^[29],塬、梁、峁皆有,沟壑相间,为典型的黄土地貌。属于半干旱温带大陆性季风气候,四季分明,年平均降水量为 496 mm^[30],且集中于 7—9 月,易发生沟沿边缘崩塌,形成泥石流造成严重的水土流失,生态环境敏感脆弱,为全国水土流失治理的重点区域,自 1998 年实施

退耕还林工程以来,植被恢复显著,被誉为“退耕还林第一县”。样区流域海拔范围为 1 192~1 772 m,面积

约为 349.75 km²,属于黄土高原沟壑区,沟沿线明显,对于正负地形分割具有典型性(图 1)。

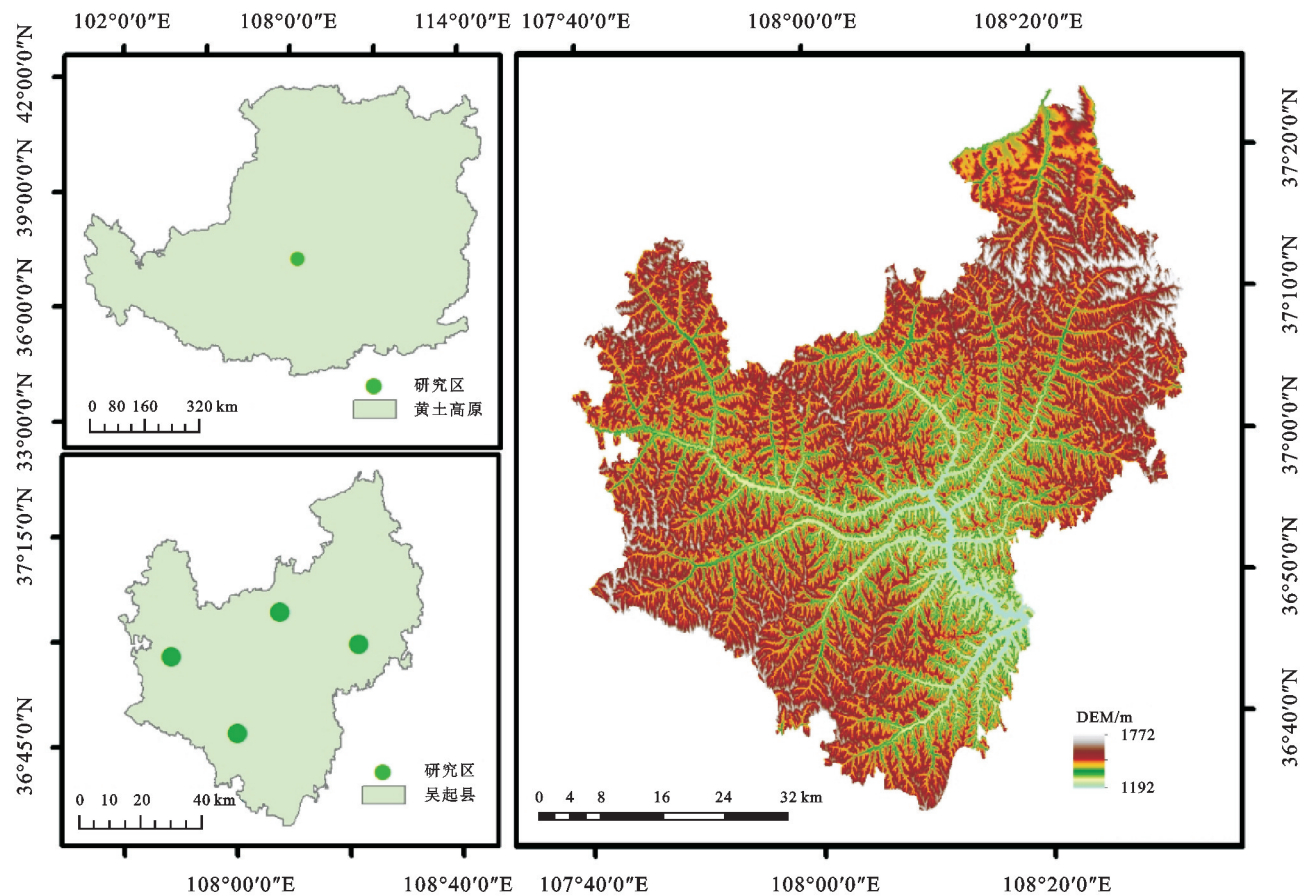


图 1 研究区概况

1.2 数据来源及预处理

本研究中以 ALOS PALSRA DEM 为基本数据源,其空间分辨率为 12.5 m,是由日本 ALOS 项目中 PALSRA 全极化雷达传感器生成,近全球(北纬 60°到南纬 59°)覆盖,通过美国国家航空航天局官网(<https://search.asf.alaska.edu/#/>)下载获得。

由 DEM 元数据中获取影像成像时间为 2007 年 1 月,在 Google Earth Pro 中经过地理匹配选择研究区的同时期或邻近月高清影像数据,并根据高清影像手绘沟沿线,见图 2。通过 ArcGIS 10.6 生成研究区

正负地形栅格作为深度学习标签数据。利用 ArcGIS 工具箱将 DEM 数据与标签样本数据成对分割为 256 像素 256 像素的图像块,共 90 幅,打乱顺序,随机分配训练图块 72 幅,验证图块 12 幅,剩下 6 幅为测试图块。利用训练图块训练图形分割模型,验证图块检验算法是否过拟合,最终通过测试图块评价不同模型间的精度。由于样本数据较少,在训练样本前需对其进行数据增强处理,数据增强过程主要包括数据旋转、数据镜像、数据长度及宽度变化、错切变换等,最终生成训练图块 2 422 幅,验证图块 34 幅。




图 2 研究区手绘沟沿线

2 研究方法

2.1 网络模型

2.1.1 Unet 基本框架 Unet 是一种语义分割框架,因其网络结构形似 U 而得名^[31],见图 3。Unet^[22-23]由两部分组成,网络左侧部分为编码器,包含四层卷积块,由最大池化连接,通过其对图像下采样提取图像浅层特征;解码器部分与编码器部分对称,卷积块间由反卷积连接,并与编码器中对应的特征图像修剪拼接,将浅特征层的空间信息与深特征层的语义信息相结合,最后通过卷积层生成分割图。Unet 通过中间跳跃连接充分利用图像特征,提高了图像分割性能与精度^[31],在图像分割领域被广泛应用,取得了显著的效果。

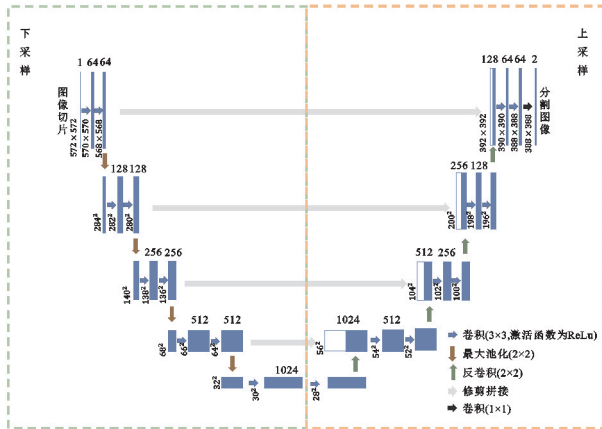


图 3 Unet 模型结构

2.1.2 残差模块 残差模块^[25-26,28]是残差网络 Res-Net 的基本单元,由恒等映射部分与跳跃连接部分组成,给定一个输入 x_l 与第 l 个残差模块输出值 x_{l+1} ,则表达式为:

$$y_l = h(x_l) + R(x_l, \omega_l)$$

$$x_{l+1} = f(y_l)$$

式中: $R(x_l, \omega_l)$ 为残差函数; $f(y_l)$ 为激活函数; $h(x_l)$ 为恒等映射函数。

2.1.3 激活函数 激活函数使卷积神经网络具有非线性,可以很好地应对复杂的图像分割问题,加快网络的收敛性与特征提取^[32]。Unet 网络框架中常用的激活函数为 ReLu 函数^[23],其表达式为:

$$\text{ReLu}(x) = \begin{cases} x & x \geq 0 \\ 0 & x < 0 \end{cases}$$

Swish 函数^[33]是一个介于线性函数与 ReLu 函数间的激活函数,具有非单调性、平滑等优点,其表达式为:

$$\text{Swish}(x) = x \times \text{sigmoid}(\beta x)$$

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

式中: β 为可训练参数。

H-Swish 函数^[34]是一个组合算子,其由 Swish 函数改进而来,两者图像相近,但 H-Swish 函数计算量比较小,减小开销,表达式为:

$$\text{H-Swish}(x) = x \times \frac{\text{ReLu6} = (x + 3)}{6}$$

$$\text{ReLu6} = \text{Min}[6, \text{Max}(0, x)]$$

2.1.4 损失函数 损失函数是用来衡量模型预测值与真实值不一致程度的非负实值函数,值越小,说明函数的鲁棒性越好^[32]。在 Unet 网络模型中,通常使用交叉熵函数作为损失函数,交叉熵代表预测值与真实值之间的距离^[32],表达式为:

$$J(y_i, p_i) = -\frac{1}{N} \sum_{i=1}^N [y_i \lg p_i + (1 - y_i) \lg (1 - p_i)]$$

式中: $J(y_i, p_i)$ 代表了交叉熵损失; i 为当前类别; y_i 为类别 i 的真实值; p_i 为类别 i 的预测值; N 为样本总数。在图像二分类模型中通常使用 binary-cross entropy 函数。

Focal loss 函数^[35]是在标准交叉熵损失函数上改进得到的,通过减少易分类样本数,使模型专注于难分类样本的训练。其表达式为:

$$F(y_i, p_i) = -\frac{1}{N} \sum_{i=1}^N [\alpha y_i (1 - p_i)^\gamma \lg p_i + (1 - \alpha)(1 - y_i) p_i^\gamma \lg (1 - p_i)]$$

式中: $F(y_i, p_i)$ 为 Focal 损失值; y_i 为类别 i 的真实值; p_i 为类别 i 的预测值; α 为权重因子; γ 为聚焦参数。

Tversky loss 函数^[36]基于 Tversky 指数提出的广义损失函数,在精度和召回率之间寻找更好的平衡,该函数在高度不平衡的数据中泛化并表现良好。其表达式为:

$$T(y_i, p_i) = \frac{\sum_{i=1}^N p_{0i} g_{0i}}{\sum_{i=1}^N p_{0i} g_{0i} + \alpha \sum_{i=1}^N p_{0i} g_{1i} + \beta \sum_{i=1}^N p_{1i} g_{0i}}$$

式中: $T(y_i, p_i)$ 为 Tversky 损失值; N 为样本总数; p_{0i} 为第 i 体素是正类的概率, p_{1i} 为第 i 体素是负类的概率; g_{0i} 为 1 代表正类,为 0 代表负类, g_{1i} 亦然。

2.1.5 卷积注意力模块 卷积注意力模块(CBAM)^[25,37]

由通道注意力模块与空间注意力模块两部分组成,从通道与空间两个角度提取特征,并根据特征重要性分配各通道信息权重,解决无效特征在分割提取特征时产生干扰的问题,提高网络模型的分割效果。本文所采用的 CBAM 模块结构图见图 4。输入特征图像 F ,通过通道注意力模块运算得到系数 M_c ,生成特征图像 F' ,然后通过空间注意力模块运算得到系数 M_s ,获得最终特征图像 F'' 。

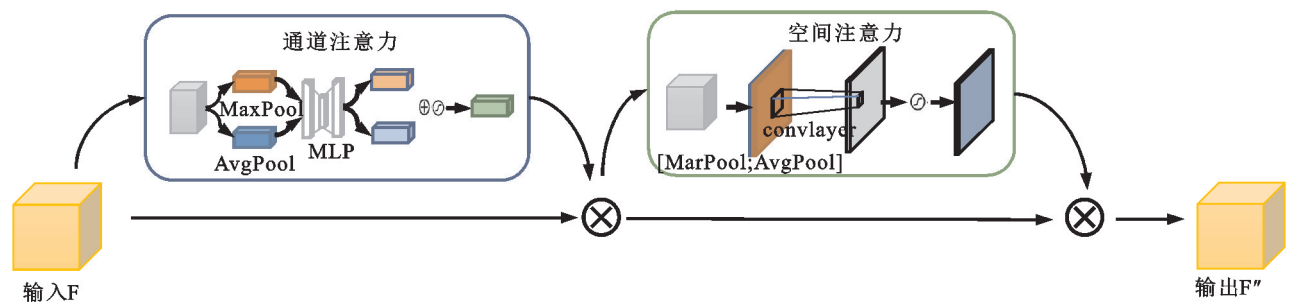


图 4 卷积注意力模块

2.2 评价指标

为了客观地评估各试验结果之间的差异,本文选取了总体精度(OA)、精确度(Precision)、召回率(Recall)、F1-Score 以及交并比(IoU)5 个指标^[28,38-39]对试验结果数据进行定量评价。OA 为预测正确的像元数与总像元数的比例,反映整体分割精度;Precision 为预测正确的正样本数占预测的正样本的比例;Recall 为预测正确的正样本数占真实的正样本的比例;Precision 反映了预测精度,Recall 反映了检出精度,都反映了算法中某一类样本的精度,但两者间存在一定的矛盾,即 Precision 最高时,Recall 不一定为最大,为了平衡两者,引入 F1-Score 对其加权调和平均,综合评估算法精度,其越高,算法性能越好;IoU 为预测值与真实值之间交集与并集之比,越接近 1,说明分割效果越好。各指标计算公式如下:

$$OA=\frac{TP+TN}{TP+TN+FP+FN}$$
$$Precision=\frac{TP}{TP+FP}$$
$$Recall=\frac{TP}{TP+FN}$$
$$F1-Score=\frac{2PR}{P+R}$$
$$IoU=\frac{TP}{TP+FP+FN}$$

式中:TP 为真实为正样本且预测也为正样本的数目;TN 为真实为负样本且预测也为负样本的数目;FP 为真实为负样本且预测为正样本的数目;FN 为真实为正样本且预测为负样本的数目;P 为精确度(Precision);R 为召回率(Recall)。

本文地形分割试验中,主要的试验环境的软硬件配置见表 1。

3 结果与分析

3.1 残差模块对地形分割精度影响

为了验证残差模块对地形分割的有效性,本研究中将残差模块替代 Unet 网络中卷积模块,构建 Res-Unet 学习网络。在试验中,学习率为 1×10^{-4} ,迭代次数为

100 次,将原始 Unet,Res-Unet 训练完成后再测试数据集对比分析,其结果见图 5。在图中可以看出,在狭小的地形中,Unet 网络分割结果存在错分,出现零星的碎块,在一些细窄地形处出现信息丢失,边缘出现黏合、不清晰现象,不能获取准确的分割线。Res-Unet 相较于 Unet 结构,通过残差模块加深了网络结构,获取更多地形语义信息,碎小斑块减少,在细小地形分割中对边缘信息更加敏感,边缘处理精度较高。

表 1 试验环境参数

参数	内容
CPU 型号	Intel(R) Xeon(R) W-2133CPU @3.60 GHz
GPU 型号	Quadro P4000
内存	128 G
操作系统	Window 10
深度学习框架	TensorFlow-gpu 1.15.0,Keras 2.3.1
编译器	python 3.7.9
CUDA	CUDA 10.0

3.2 选取激活函数与损失函数

激活函数与损失函数对模型的鲁棒性与分割精度有至关重要的作用,本试验中模型采用了两种激活函数(swish 函数、H-swish 函数)与 3 种损失函数(Focal loss 函数、Tversky loss 函数、binary-cross entropy 函数),通过对比模型训练时的收敛性能以及对测试数据结果定性定量的评价,选取在地形分割过程模型中最优的激活函数与损失函数。图 6 为几种损失函数试验的训练损失曲线,可以看出 Focal 损失函数收敛最快,约 40 次就趋于平缓,Tversky 函数次之,binary-cross entropy 函数收敛最慢,约需要 80 次才达到收敛。

图 7 为不同激活函数与损失函数的组合的测试集结果。从图中可以看出 Focal loss 函数结果集的碎小地形少于其他两种损失函数,边缘信息更为清晰,椒盐噪点基本消失,尤其在一些正负地形失衡地区;而 binary-cross entropy 函数在分割时存在分割不足的现象,导致地形误判,出现错分地形;Tversky loss 函数在分割时过度分割,边缘出现粘连,出现错分或者形成地形空洞。




图 5 Unet 与 Res-Unet 结果对比




图 6 不同损失函数模型训练 loss 曲线

表 2 为不同激活函数与损失函数的训练模型在测试数据集上精度评价指标。通过对比可以发现,在地形分割中 H-Swish 激活函数相较于 Swish 函数整体性能都有一定的提升,就整体精度而言,Focal 函数提升较少,约 0.1%,binary-cross entropy 与 Tversky 函数都提高了约 0.4%。binary-cross entropy 函数、Focal 函数、Tversky 函数 3 个损失函数相比,Focal 函数的整体精度最好,binary-cross entropy 函数次之,Tversky 函数较低。其中 Swish 激活函数与 Tversky 损失函数组合时,地形分割模型错分现象较多,导致正、负地形的精确度失衡,差异较大,整体精度为最低。

3.3 注意力模块对地形分割精度影响

通过将残差模块替换 Unet 模型中的卷积模块,


选取分割效果较好的 H-Swish 激活函数与 Focal 损失函数组合,并在跳跃连接中引入注意力模块,构成本试验的改进型 Unet 地形分割模型,结构图见图 8。卷积注意力模块平衡通道注意力与空间注意力,在跳跃连接时减少干扰信息,增加有效信息的传递。

利用坡面畸变邻域判断法^[9]对验证数据集进行正负地形分割,并与网络模型提取结果对比。首先根据地形特征判断,利用 DEM 计算坡度,并提取坡度大于 15° 区域的 DEM。然后对提取的 DEM 利用均值变点法确定最佳邻域统计单元为 18×18 ,计算邻域均值,分割正负地形;将坡度小于 15° 的区域根据高程均值分为正负地形。最后将两类坡度下的正负地形合并得到整体地形分割数据。图 9 为改进型 Unet 模型测试集试验结果与坡面畸变邻域判断法提取结果对比,坡面畸变邻域判断法在坡度较小区域(坡度 $< 15^\circ$)即地势比较平坦区域分割效果差,出现成片错分现象,这是由于平坦区域分割正负地形时阈值选取存在主观性,边界不清晰,具有较大的误差。

表 3 为改进型 Unet 地形分割模型与坡面畸变邻域判断法在测试数据集的各项指标对比。与原始 Unet 训练模型相比,本文提出的改进型 Unet 模型整体性能较优,各项指标都有较大的提升,整体精度提升了 1.2%,负地形方面,精确度提升较大,约为 2.4%,召

回率提升 0.3%,F1-Score 提升了 1.3%,IoU 提升 1.9%;正地形方面,精确度略微提升了 0.4%,其他指标提升都在 1%以上,分别提升了 1.7%,1.0%,1.7%。相较于传

统的坡面畸变邻域判断法,网络训练模型在各个指标都很大的提升,其中本文提出的改进型 Unet 地形分割模型在整体精度上提高约 16%。



注:A 表示 DEM 数据;B 表示标签数据;C 表示 RB+H-Swish+binary-cross entropy 模型结果;D 表示 RB+H-Swish+Focal 模型结果;E 表示 RB+H-Swish+Tversky 模型结果;F 表示 RB+Swish+binary-cross entropy 模型结果;G 表示 RB+Swish+Focal 模型结果;H 表示 RB+Swish+Tversky 模型结果。

图 7 不同激活函数与损失函数的组合的结果对比

表 2 不同激活函数与损失函数指标对比结果 %

参数		binary-cross entropy		Focal		Tversky	
		负地形	正地形	负地形	正地形	负地形	正地形
Swish	Precision	80.7	87.8	80.7	88.3	76.0	90.1
	Recall	79.0	88.9	80.0	88.7	84.2	84.3
	F1-Score	79.8	88.3	80.3	88.5	79.8	87.1
	IoU	66.4	79.1	67.1	79.4	66.5	77.2
	OA	85.2		85.5		84.3	
H-Swish	Precision	80.3	88.8	80.3	88.8	80.0	87.4
	Recall	81.0	88.3	81.1	88.3	78.3	88.5
	F1-Score	80.6	88.5	80.7	88.5	79.1	87.9
	IoU	67.5	79.4	67.6	79.4	65.5	78.5
	OA	85.6		85.6		84.7	

4 讨论

通过测试数据集结果对比分析,改进型 Unet 模型能有效地区分正负地形,故将其应用于黄丘区地形分割。将深度学习分割结果与 Google 高清影像叠合

分析(图 10),可以看出,本文提出的模型对正负地形有较好的识别效果,具有较高的精度。在黄土塬区域,大面积正地形被很好地分割出来,内部不存在零碎的错分地形,正负地形间有清晰的分界线,出现错分现象少,但由于模型分割过程需数据分块进行后合

并处理,因此在数据分块边缘处存在错分现象,见图 10。在黄土梁区域,沟壑纵横,沟沿线密度大,地形较

为复杂,模型提取结果较好地识别了正负地形,但内部存在零星的地形孤岛。

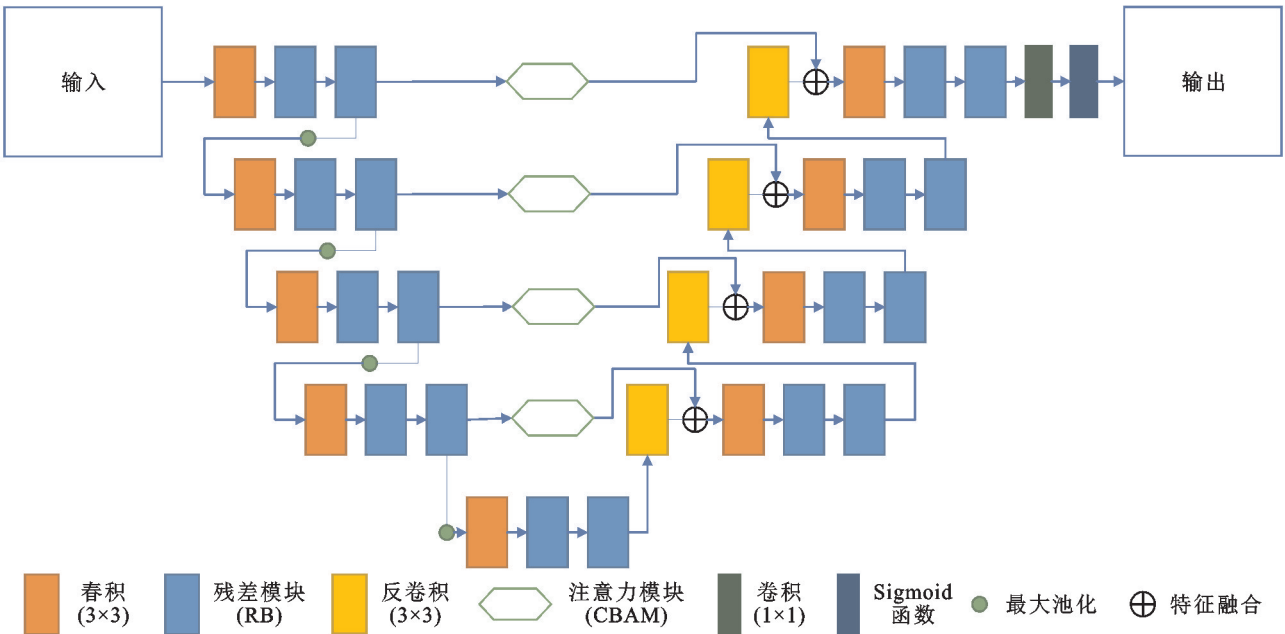


图 8 改进型 Unet 结构




图 9 地形分割结果对比((A)为 DEM 数据;(B)为标签数据;(C)为改进型 Unet 模型结果;(D)为坡面畸变邻域判断法结果)

改进型 Unet 模型相较于原始 Unet 模型,具有较深的网络结构并解决了因网络深度而引起的性能退化及梯度消失的问题,可以训练更深的网络,提取更深层次更丰富的语义信息。同时加入卷积注意力模块,增加模型抗干扰能力,减少了无效信息。

总体而言,改进型 Unet 模型可以有效地提取正

负地形,但试验样本制作较为困难,因此后续研究中还需继续收集大量地形分割数据集,增加样本多样性,进而提高复杂地形的分割精度。

此外,目前地形分割后还存在少量的零碎地形及地形孤岛,后续提取过程中在改进型 Unet 模型分割后引入全连接条件随机场增强地形边缘信息,

对分割结果进一步精准识别,减少地形噪点,优化分割效果。

表 3 不同网络模型指标对比结果					%	
参数		Precision	Recall	F1-Score	IoU	OA
Unet	负地形	78.9	81.0	80.0	66.6	85.0
	正地形	88.6	87.3	88.0	78.5	
Res-Unet	负地形	79.1	81.2	80.2	66.8	85.1
	正地形	88.8	87.4	88.1	78.7	
改进型 Unet	负地形	81.3	81.3	81.3	68.5	86.2
	正地形	89.0	89.0	89.0	80.2	
坡面畸变邻域	负地形	58.5	68.8	63.2	46.2	70.3
判断法	正地形	79.5	71.2	75.2	60.2	




图 10 改进型 Unet 模型分割结果

数据尺度是空间分析中一个关键问题,数据尺度的不确定性影响着结果的提取精度。正负地形分割精度受到 DEM 分辨率的影响。此前,Dai^[12]在 DEM 分辨率对沟壑提取分析中,0.5~2 m 分辨率为小流域沟壑绘制分析最佳分辨率,过高的分辨率导致沟沿线上移,扩大了负地形面积,而较低分辨率会使沟沿线下移,减少了负地形的面积。但在大范围区域正负地形分割中,最佳分辨率尚未有定论。过高分辨率的 DEM 数据具有更多地形特征,但过于在乎微地形,造成数据噪点影响模型分割效果,产生地形孤岛,沟沿线表达地形效果差;而低分辨率的 DEM 数据忽略了过多地形细节,造成沟沿线偏移。本文研究中数据采用 12.5 m 的 DEM 单一地形因子,后续研究中将讨论大范围内多种分辨率与沟沿线提取精度的相关性,并引入其他地形因子参与模型训练,探讨最佳分割组合与分辨率。

5 结论

基于 Unet 模型架构,引入残差模块与卷积注意

力模块,并对 Relu 激活函数与 binary-cross entropy 损失函数优化,选择性能与精度更优的 H-Swish 激活函数与 Focal 损失函数组合,构建改进型 Unet 深度学习模型对大范围的地形进行分割。残差模块加深了网络结构,获取更深层地形语义信息,丰富地形边缘信息,提升分割边缘精度,H-Swish 激活函数与 Focal 损失函数避免模型神经元失活及加快模型收敛速度。

在地形测试数据集中,改进型 Unet 深度学习模型总体精度达到了 86.2%,正地形的精确率、召回率、F1-Score 均为 89.0%,IoU 为 80.2%,负地形的精确率、召回率、F1-Score 均为 81.3%,IoU 为 68.5%,相较于 Unet 模型都有较大的提升。坡面畸变邻域判断法分割结果总体精度为 70.3%,相较而言,基于深度学习模型的地形分割效果更优,各项指标都有很大的提升,其中改进型 Unet 模型总体精度提高约 16%,错分漏分现象更少。

参考文献:

[1] 李锐.中国黄土高原研究与展望[M].北京:科学出版社,2008:1-3.

[2] 甘枝茂.黄土高原地貌与土壤侵蚀研究[M].西安:陕西人民出版社,1989:3-6.

[3] 许强,陈婉琳,蒲川豪,等.基于自然的解决方案在黄土高原重大工程灾变防控中的理论与实践[J].工程地质学报,2022,30(4):1179-1192.

[4] 穆兴民,李朋飞,刘斌涛,等.1901—2016 年黄土高原土壤侵蚀格局演变及其驱动机制[J].人民黄河,2022,44(9):36-45.

[5] 刘迪,陈海,耿甜伟,等.基于地貌分区的陕西省区域生态风险时空演变[J].地理科学进展,2020,39(2):243-254.

[6] 汤国安,那嘉明,程维明.我国区域地貌数字地形分析研究进展[J].测绘学报,2017,46(10):1570-1591.

[7] 程维明,周成虎,申元村,等.中国近 40 年来地貌学研究的回顾与展望[J].地理学报,2017,72(5):755-775.

[8] 罗来兴.划分晋西、陕北、陇东黄土区域沟间地与沟谷地的地貌类型[J].地理学报,1956,22(3):201-222.

[9] 周毅.基于 DEM 的黄土高原正负地形及空间分异研究[D].南京:南京师范大学,2011.

[10] 张磊,汤国安,李发源,等.黄土地貌沟沿线研究综述[J].地理与地理信息科学,2012,28(6):44-48.

[11] Yang Xin, Li min, Na Jiaming, et al. Gully boundary extraction based on multidirectional hill-shading from high-resolution DEMs[J]. Transactions in Gis, 2017, 21(6):1204-1216.

[12] Dai Wen, Yang Xin, Na Jiaming, et al. Effects of

- DEM resolution on the accuracy of gully maps in loess hilly areas[J]. *Catena*, 2019,177:114-125.
- [13] Zhou Yi, Tang Guoan, Yang Xin, et al. Positive and negative terrains on northern Shaanxi Loess Plateau[J]. *Journal of Geographical Sciences*, 2010,20(1):64-76.
- [14] 刘鹏举,朱清科,吴东亮,等.基于栅格 DEM 与水流路径的黄土区沟缘线自动提取技术研究[J].*北京林业大学学报*,2006,28(4):72-76.
- [15] 王轲,王琤,张青峰,等.地形开度和差值图像阈值分割原理相结合的黄土高原沟沿线提取法[J].*测绘学报*, 2015,44(1):67-75.
- [16] Na Jiaming, Yang Xin, Dai Wen, et al. Bidirectional DEM relief shading method for extraction of gully shoulder line in loess tableland area[J]. *Physical Geography*, 2018,39(4):368-386.
- [17] 晏实江,汤国安,李发源,等.利用 DEM 边缘检测进行黄土地貌沟沿线自动提取[J].*武汉大学学报:信息科学版*,2011,36(3):363-367.
- [18] Jiang Sheng, Tang Guoan, Liu Kai. A new extraction method of loess shoulder-line based on Marr-Hildreth operator and terrain mask[J]. *Plos One*, 2015,10(4): e0123804.
- [19] 周毅,汤国安,习羽,等.引入改进 Snake 模型的黄土地形沟沿线连接算法[J].*武汉大学学报:信息科学版*, 2013,38(1):82-85.
- [20] 宋效东,汤国安,周毅,等.基于并行 GVF Snake 模型的黄土地貌沟沿线提取[J].*中国矿业大学学报*,2013,42(1):134-140.
- [21] 刘玮,李发源,熊礼阳,等.基于区域生长的黄土地貌沟沿线提取方法与试验[J].*地球信息科学学报*,2016,18(2):220-226.
- [22] Ronneberger Olaf, Fischer Philipp, Brox Thomas. U-net:Convolutional networks for biomedical image segmentation[C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2015:234-241.
- [23] 许玥.基于改进 Unet 的遥感影像语义分割在地表水体变迁中的应用[D].重庆:重庆师范大学,2019.
- [24] 卫佳杰.基于 U-Net 和注意力机制的双源遥感图像语义分割方法研究[D].西安:西安电子科技大学,2020.
- [25] 徐佳伟,刘伟,单浩宇,等.基于 PRCUnet 的高分遥感影像建筑物提取[J].*地球信息科学学报*,2021,23(10): 1838-1849.
- [26] Cao Kaili, Zhang Xiaoli. An improved res-unet model for tree species classification using airborne high-resolution images[J]. *Remote Sensing*, 2020,12(7):1128.
- [27] Hou Yuewu, Liu Zhaoying, Zhang Ting, et al. C-UNet; Complement UNet for Remote Sensing Road Extraction[J]. *Sensors*, 2021,21(6):2153.
- [28] Nagi Anmol Sharan, Kumar Devinder, Sola Daniel, et al. RUF: Effective Sea Ice Floe Segmentation Using End-to-End RES-UNET-CRF with Dual Loss [J]. *Remote Sensing*, 2021,13(13):2460.
- [29] 王桢,吴金华,白帅,等.黄土丘陵沟壑区耕地细碎化评价与土地整治工程分区:以吴起县为例[J].*水土保持研究*,2022,29(4):300-307.
- [30] 刘长海,葛瑶,秦家风,等.吴起县不同土地利用类型土壤物理性质特征[J].*延安大学学报:自然科学版*,2022, 41(2):77-82.
- [31] 王旭冉.基于改进 U-Net 的遥感影像语义分割研究[D].银川:宁夏大学,2020.
- [32] 田萱,王亮,孟祥光.基于深度学习的图像语义分割技术[M].北京:海洋出版社,2019:86-87.
- [33] Ramachandran P, Zoph B, Le Q V. Searching for activation functions [J]. *Arxiv Preprint ArXiv*: 1710.05941, 2017, Doi:org/10.48550/arXiv.1710.05941.
- [34] Howard Andrew, Sandler Mark, Chu Grace, et al. Searching for mobilenetv3[C]. *Proceedings of the Ieee/Cvf International Conference on Computer Vision*, 2019:1314-1324.
- [35] Lin Tsung Yi, Goyal Priya, Girshick Ross, et al. Focal loss for dense object detection[C]. *Proceedings of the Ieee International Conference on Computer Vision*, 2017: 2980-2988.
- [36] Salehi Seyed Sadegh Mohseni, Erdogmus Deniz, Gholipour Ali. Tversky loss function for image segmentation using 3 D fully convolutional deep networks[C]. *International Workshop on Machine Learning in Medical Imaging*. Springer, Cham, 2017:379-387.
- [37] Woo Sanghyun, Park Jongchan, Lee Joon Young, et al. Cbam: Convolutional block attention module [C]. *Proceedings of the European Conference on Computer Vision(Eccv)*,2018:3-19.
- [38] 王海涛,王一琛,王永强,等.基于 MS-UNet 的 Landsat 影像云检测[J].*激光与光电子学进展*,2021,58(14): 87-94.
- [39] Jiao Libin, Huo Lianzhi, Hu Changmiao, et al. Refined UNet: UNet-based refinement network for cloud and shadow precise segmentation [J]. *Remote Sensing*, 2020,12(12):2001.