引文格式：曹南,李昕,刘小龙,等. 基于深度学习的DSM林地自动降高研究[J]. 地理空间信息, 2024, 22(8): 37-40. doi:10. 3969/j.issn. 1672-4623.2024.08.008

基于深度学习的DSM林地自动降高研究

曹　南[1]，李　昕[1]，刘小龙[1]，段文辉[1]
（1. 自然资源部第一地形测量队，陕西 西安 710054）

摘　要：将DSM看做单通道图像，林地区域视为空洞区域，将降高视为图像修复过程进行研究。首先利用HRNet-OCR深度学习模型经训练和推理识别林地区域，构建降高模型训练样本与分类信息；然后利用RFRNet深度学习模型经训练和迭代构成自动降高模型，进行自动降高；最后利用高程归一化算法将待降高区域和训练数据统一到同一高程面，同时加入高程值修正，构成最终的自动降高成果。结果表明，深度学习可以实现DSM林地区域的自动降高，且降高结果会形成较多的可替补范围，应用于DEM项目生产。

关键词：深度学习；HRNet-OCR；RFRNet；DSM自动降高；高程归一化
中图分类号：P282　　**文献标志码：**B　　**文章编号：**1672-4623（2024）08-0037-04

Research on DSM Forest Automatic Height Reduction Based on Deep Learning

CAO Nan[1], LI Xin[1], LIU Xiaolong[1], DUAN Wenhui[1]
(1. The First Topographic Surveying Brigade of MNR, Xi'an 710054, China)

Abstract: In this paper, we considered DSM as a single channel image, the woodland area as a hollow area, and the elevation reduction process as an image restoration process. Firstly, we used the HRNet-OCR deep learning model to identify woodland areas through training and reasoning, and constructed the training samples and classification information of elevation reduction model. Then, we trained and iterated the RFRNet deep learning model to form an automatic height reduction model for automatic height reduction. Finally, we used the elevation normalization algorithm to unify the area to be reduced and the training data to the same elevation plane, and added the elevation value correction to form the final automatic height reduction result. The results show that deep learning can achieve automatic height reduction of DSM forest, and the results of height reduction will generate more alternative ranges, which can be applied to DEM project production.

Key words: deep learning, HRNet-OCR, RFRNet, DSM automatic height reduction, elevation normalization

数字摄影测量是以数字影像为基础，利用全自动影像匹配技术开展密集点云匹配，构建规则格网数字表面模型（DSM），进而通过人机交互编辑生成高精度DEM。DSM编辑工作主要采用全立体人工编辑，通过人工判读，确定需降高区域及降高值，将林地从地表降至地面，且地形满足精度要求。这种方法的特点是数据来源较多、作业过程简单，缺点是图幅上通常林地分布范围广且不均，林层高度不一，目视判读林地冠层高度困难，作业过程需逐地块人工编辑处理，工作量大、自动化程度低，是制约DEM生产效率提升的主要因素[1-5]。

目前针对DSM林地的自动降高尚没有成熟可靠的方法。在生产中通常利用Link软件，利用其自带的分类功能，进行林地和非林地分类，然后统一给定降高值并自适应平滑处理，逐块在立体上确认，能够在一定程度上提高生产效率。这种方法存在统一降高值无法代替实际林高、工作量仍很大等问题，仅能起到辅助降高作用。基于以上现状，本文提出一种基于深度学习的DSM林地自动降高方法，将DSM视为单通道图像[6]，利用图像分类算法提取同区域影像林地区域作为空洞区域，然后基于图像修复算法，对DSM林地区域进行修补，最终构成完整的DSM图像。

1　方法原理与流程

基于深度学习的DSM林地自动降高方法的理论依据是遥感图像恢复理论，即根据退化模型将退化图像尽可能地还原成接近于理想图像或客观真实的图像[7]。由于DSM只含有高程格网值，因此可以将DSM数据看作是单通道的影像，将林地区域看作缺失区

收稿日期：2023-04-23。
项目来源：陕西测绘地理信息局科技创新经费资助项目（SCK2021-07）。
第一作者简介：曹南（1988—），硕士，工程师，研究方向为遥感影像处理，E-mail：453637557@qq.com。

域，以深度学习理论构建退化模型，对缺失区域进行修补，将此过程视为DSM林地自动降高的过程。

在进行图像修补之前，使用同区域或相似区域的DEM和DSM样本数据进行训练学习，由于DEM和DSM的差别主要体现在林地上（忽略建筑物、桥梁等影响），通过学习得到体现林地和非林地差别的深度学习模型，进而通过推理得到修补区域的真实地面高程。

2 关键技术

2.1 基于HRNet-OCR的林地区域识别

HRNet-OCR结构由HRNet和OCR模块组合而成，构建基于OCR模块的HRNet-OCR林地区域识别算法，对林地进行提取。

算法的骨干网络采用HRNet（high-resolution Net）。HRNet网络在对特征降采样的同时，不断对高分辨率的特征层进行卷积，并在每个阶段整合多层次的特征层，可充分利用图像不同层次的特征信息，最大限度保留信息，强化上下文语义特征的提取能力[8]。HRNet在整个过程中保持高分辨率的特征表示以及在并行的多分辨率子网之间反复交换信息，进行多尺度融合，高、低分辨率特征之间相互增强。

OCR（object contextual representations）由多层注意力机制构成，包括了软物体区域模块、物体区域表示模块、区域-像素表达模块、上下文信息聚合模块[9]。自注意力机制通过计算特征图中每个像素点与其他像素点间的亲和力来表达该像素点的重要性。在本次研究中林地区域作为前景目标，自注意力机制可以建立起林地像素与其他像素的空间关系，聚合上下文信息，从而增强其作为前景目标的信息表达。

2.2 基于RFRNet的DSM林地自动降高

循环特征推理网络（recurrent feature reasoning net，RFRNet）是一种图像修复算法，其过程是给出图像及待填充的区域掩码，计算修复后的图像。本项目将图像修复网络引入到DSM自动降高，将DSM图像看做单通道的图像，将图像上林地区域看做空洞区域，利用RFRNet模型修复空洞区域[10]。

2.2.1 循环特征推理模块

1）区域识别。区域识别模块确定当前迭代需要更新的区域，实际上完成掩码生成的任务，得到的掩码是待填充区域收缩一圈的结果。该模块所使用的卷积层是局部卷积层（Partial Convolutional Layer），可以将有效像素（Unmaskpixels）和无效像素（Maskpixels）区别对待，卷积层只对有效像素做操作。区域识别描述如式（1）：

$$f^{*}_{x,y,z}=\begin{cases}W_z^{\mathrm{T}}\left(f_{x,y}\odot m_{x,y}\dfrac{\mathrm{sum(1)}}{\mathrm{sum}(m)}\right)+b\\0,\end{cases}\tag{1}$$

式中，$f_{x,y}$、$m_{x,y}$为以（x，y）为中心的特征图和掩码图；W_Z为局部卷积层输出的第z个卷积核；比例系数用于扩大有效点权重，当不存在时特征图输出0。掩码图$m^{*}_{x,y}$更新较为简单，描述如式（2）：

$$m^{*}_{x,y}=\begin{cases}1,\ \mathrm{sum}(m)\ !=0\\0,\ \mathrm{else}\end{cases}\tag{2}$$

2）特征推理。特征推理模块对于区域识别模块输出的此轮待填充区域，使用网络做填补。特征推理模块采用encoder-decoder结构，模块的输入，包含一个特征图以及当前轮次的掩码，网络输出只有当前轮次掩码图修复后的特征图。区域识别模块和特征推理模块串联起来被重复若干次，每一次循环，特征推理模块的输出都被作为下一轮区域识别的输入。

3）特征融合。经过连续几轮“区域识别+特征推理”之后得到的特征图，可以直接使用真值做约束，由于层数过多，容易造成梯度消失现象，需要把监督信息引入到前面几个轮次的输出中，为此需要将几个轮次输出的特征图做特征融合，使用自适应融合机制，只对已填充的区域自适应地进行融合，最终输出的特征图定义如式（3）：

$$\bar{f}_{x,y,z}=\frac{\sum_{i=1}^{N}f^{i}_{x,y,z}}{\sum_{i=1}^{N}m^{i}_{x,y,z}}\tag{3}$$

式中，N为特征图数量。

2.2.2 认知连贯注意力机制

使用传统的Attention机制，发现每个轮次是相互独立计算的，在融合时会相互干扰。本文使用的认知连贯注意力机制（KCA）打破了上述机制，融合了相邻2次循环中的信息计算Attention Score来控制特征图的不连续性。认知过程描述如下：

1）计算背景像素和空洞像素的特征相似度，特征图定义为F，特征图的所有像素都要按式（4）计算相似度：

$$\widehat{\mathrm{sim}}^{i}_{x,y,x',y'}=\left\langle\frac{f_{x,y}}{\left\|f_{x,y}\right\|},\frac{f_{x',y'}}{\left\|f_{x',y'}\right\|}\right\rangle\tag{4}$$

式中，F为(x,y)处的值；$f_{x,y}$$i$为当前循环的次数。

2）对目标像素和周围像素平均相似度做平滑，选取点 (x,y) 的 $k\times k$ 邻域，对邻域内逐点做相似度计算并取平均，描述如下：

$$\mathrm{sim}'^{i}_{x,y,x',y'}=\frac{\sum_{p,q\in\{-k,\cdots,k\}}\widehat{\mathrm{sim}}_{x+p,y+q,x',y'}}{k\times k} \tag{5}$$

3）为解决每次特征图可能不一致的问题，KCA模块在每次迭代不会计算一个独立的Attention score，对于本轮次有效，但上一次无效的点，直接选择本轮次结果；对于本轮次和前一轮次均有效的点，加权平均。

4）最后根据Attention score构建特征图，新的特征图像素（x，y）计算如下：

$$\hat{f}^{i}_{x,y}=\sum_{x'\in 1,\cdots,W,y'\in 1,\cdots,H}\mathrm{score}^{i}_{x,y,x',y'}f^{i}_{x',y'} \tag{6}$$

式中，i 为迭代轮次；W、H 为特征图宽、高。

5）在特征图重构后，输入的特征 F 和重构的 $\hat{F}$ 经过一层像素排列卷积运算 φ 得到最终的重建特征图 F'。

$$F'^{i}=\varnothing\left(\left|\hat{F},F\right|\right) \tag{7}$$

2.3　不同DSM高程归一化

由DSM生成的训练数据是像素值为高程的图像数据，将数值差异大的数据输入到神经网络中会加大模型学习中的数据扰动，使参数修正变得困难[11]。归一化是以合理保留其动态范围方式规范化缩放操作输入数据，使高程值落入较小的特定区间，消除高程不一致影响。

利用RFRNet对DSM、DEM构成的样本数据集做模型训练，实现对单通道的DSM图像的修复，修复的过程需保持样本数据与推理数据高程面一致，否则会由于地形的不一致造成“削地形”的现象，需要在推理之前对数据进行高程归一化操作。高程归一化的思路是将不同高程的数据转化到同一高程面上。计算公式为：

$$H=H'-R \tag{8}$$

式中，H 为归一化后的高程值；H' 为推理数据中像素的原始高程值；R 为归一化参数，R 的计算方式为：

$$R=H'_{\min}-H_{\min} \tag{9}$$

在推理完成后，对推理结果的高程值进行还原，公式如下：

$$H'=H+H'_{\min}-H_{\min} \tag{10}$$

2.4　高程值修正

经高程归一化进行DSM数据推理，获取DSM自动降高成果，由于归一化操作，地形基本形态得以保留，存在的主要问题是降高精度不达标，需要针对区域林地特点加特定的修正值；另外模型针对全图幅进行推理，对于无林区域也进行了地形修正，需要使用林地区域识别结果替换原有无林区域数据，并在边缘使用高斯平滑算法[12]进行平滑过渡，保证有林区和无林区的光滑过渡。

3　降高实验及结果分析

3.1　实验数据

本实验采用南美洲巴西地区数据，数据种类包括DOM、DSM和DEM。其中DOM数据作为林地识别算法的训练样本构建林地识别模型，同时为自动降高模型提供分类信息；DSM和DEM数据作为林地降高算法的训练样本，用于进行林地自动降高模型的构建。实验数据基本信息如表1。

表1　实验数据信息

种类	数量/幅	分辨率/m	分幅
DOM	10	2	1∶10 000
DSM	10	10	1∶10 000
DEM	10	10	1∶10 000

在实验时需保持分类信息、DSM、DEM数据命名及范围一致，通过DOM采集林地区域范围矢量，经矢量栅格化构成林地分类信息。在模型训练时以4∶1的比例划分训练集和验证集，将数据经裁剪为小影像后送入模型。模型训练完毕后经高程归一化、模型推理、高程值修正获取最终的降高结果。

3.1.2　实验环境

1）硬件配置：CPU64 U，内存256 G，显存Tesla V100（16 G），硬盘1 T。

2）软件配置：操作系统Ubantu18.04.2 LTS 64位，编程语言Python 3.7，深度学习框架PyTorch，函数库OpenCV、GDAL等。

3.2　结果与分析

使用深度学习模型进行自动降高实验，分3个试验阶段：原始模型降高结果、高程归一化后降高结果和加入高程值修正降高结果，后一个过程是对前一过程降高精度不足的改进。对降高结果精度的评定，可以用平均绝对误差[13]（MAE，mean absolute error）评定。但在实验中发现，MAE只能体现平均降高效果，用它来进行降高结果精度评定，与实际降高效果偏差较大，因此在实际中通过在立体上查看评估的方式。

3.2.1　原始模型降高结果及分析

对待降高区域采用原始模型进行降高，获取原始模型降高成果，将其与原始DSM及DEM成果（真值）做渲染对比，结果如图1。

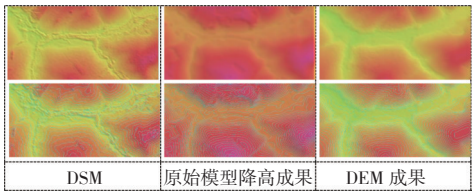


图1 原始模型降高结果对比

图中，林地区域原始模型降高成果较原始DSM对林地区域进行了一定程度的降高，等高线也较原始的DSM更加平滑，接近真值（DEM）。通过在立体下查看降高结果发现：全图幅虽然在一定程度上实现了自动降高，但图幅上部分山脊被“削”平，植被茂密的区域降高程度不够。

对使用原始模型的训练数据及降高结果进行分析发现：训练样本和待降高区域数据高程相差过大，考虑产生山脊“削”平现象是由高差不一致造成，下一步的实验方向是对待降高区域进行高程归一化。

3.2.2 高程归一化后降高结果及分析

在对待降高区域使用模型降高之前，先高程归一化，将待降高区域和训练样本高程统一到同一个高程平面上，降高结果如图2。

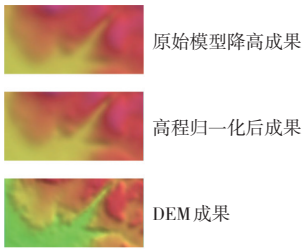


图2 加高程归一化后降高结果对比

将图中降高结果在立体下查看发现：高程归一化后成果山脊“削”平现象得到显著改善，保持了原有的地形地貌，但在图幅上绝大部分位置降高精度达不到要求，需要人工辅助继续降高，为此继续降高以增加可使用的图像范围。

3.2.3 加入高程值修正的降高结果及分析

对已完成的降高成果依据研究区域林地高度规律，确定高程修正因子 h'，对未达到降高要求的区域加高程修正因子，并使用林地分类信息对非林地区域进行替换，获取最终加入高程值修正的降高成果，结果如图3。

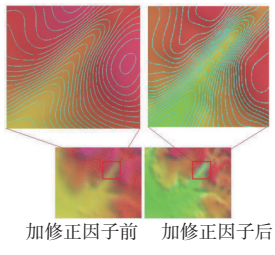


图3 加高程修正因子降高结果对比

图中，加入高程值修正的成果在有林沟谷等不易推测降高高度的区域，等高线相对此前更为陡峭，特征也更为深入，说明在这些区域进行了有效的降高。将上述结果加入立体环境中进行验证，能够在生产中有效替补的区域明显增加。

4 结 语

随着人工智能技术研究的逐步深入，深度学习被越来越多地应用于项目生产，解决生产中人工重复劳动、工作强度大的问题。本文针对分布范围广、降高难度大的林地区域，将DSM数据视为单通道的图像，使用深度学习模型，通过模型的训练和推理得到自动降高成果，并对降高成果进行高程归一化和高程值修正操作，达到DSM自动降高生成DEM成果的目的。

参考文献

[1] 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

[2] 李德仁,龚健雅,朱欣焰. 我国地球空间数据框架的设计思想与技术路线[J]. 武汉大学学报(信息科学版),1998,23(4):297-303

[3] 罗祎敏. 深度学习理论在点云数据植被剔除问题中的应用[D]. 武汉:武汉大学,2018

[4] 刘曦霞. 合成孔径雷达干涉测量(INSAR)技术原理及应用发展[J]. 科技创新与应用,2015(20):36-37

[5] 郑若琳,洪亮. 机载激光雷达的优势与发展[J]. 地理空间信息,2018,16(2):37-39

[6] 官恺,刘智,金飞,等. 一种用于DSM局部缺失的深度学习修复算法[J]. 测绘科学技术学报,2020,27(3):281-286

[7] 王军军. 图像修复和去云方法研究[D]. 西安:西安电子科技大学,2021

[8] 陈智朗,付振华,朱紫阳,等. 基于HRNet的高分辨率遥感影像建筑物变化信息提取[J]. 测绘通报,2022(5):126-132

[9] 韦任,范蓓蕾,赵子娟,等. 基于HRNet-OCR模型的农村宅基地提取方法[J]. 中国农业信息,2022,34(3):70-80

[10] 朱张莉,饶元,吴渊,等. 注意力机制在深度学习中的研究进展[J]. 中文信息学报,2019,33(6):1-11

[11] 薛凯凯. 基于UAV的黄土地貌区精细DEM生成方法研究[D]. 南京:南京师范大学,2020

[12] 谢勤岚. 图像降噪的自适应高斯平滑滤波器[J]. 计算机工程与应用,2009,45(16):182-184

[13] 茆诗松. 概率论与数理统计教程[M]. 武汉:高等教育出版社,2004