

基于深层残差网络的山区DEM超分辨率重构

张宏鸣¹ 全凯¹ 杨亚男¹ 杨江涛² 陈欢¹ 郭伟玲³

(1. 西北农林科技大学信息工程学院, 陕西杨凌 712100; 2. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;
3. 安徽理工大学测绘学院, 淮南 232001)

摘要: 针对大区域高分辨率数字高程模型(DEM)数据较难获取、超分辨率重构(降尺度)较低分辨率的DEM精度不高、难以满足实际需要的问题,提出一种对起伏特征较明显的山区DEM超分辨率重构的方法。利用较深层的神经网络充分学习高低分辨率DEM之间的非线性映射关系;为了降低训练难度,结合残差学习的方法进行数据训练。将双立方插值法、稀疏混合估计法重构的DEM及提取的坡度结果分别同深层残差网络法的结果进行对比,结果表明,3种方法DEM结果的差值平均值分别为0.41、0.34、0.34 m, RMSE分别为0.594 5、0.571 5、0.486 9 m;坡度结果的差值平均值分别为3.02°、2.04°、1.99°, RMSE分别为3.649 8°、3.136 0°、2.738 7°;处理时间分别为0.052、663.39、2.16 s。研究表明,对于10、20、40 m的DEM,本文方法在空间分布和误差方面优于其他方法,在耗时效率上也优于稀疏混合估计法,适合应用于梯田等地形复杂的区域进行超分辨率重构。

关键词: 山区; 数字高程模型; 超分辨率重构; 坡度; 深层残差卷积神经网络

中图分类号: S127 文献标识码: A 文章编号: 1000-1298(2021)01-0178-07 **OSID:** 

Super-resolution Reconstruction of DEM in Mountain Area
Based on Deep Residual Network

ZHANG Hongming¹ QUAN Kai¹ YANG Ya'nan¹ YANG Jiangtao² CHEN Huan¹ GUO Weiling³

(1. College of Information Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

3. School of Geomatics, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: High-resolution digital elevation model(DEM) in large districts is difficult to be acquired due to the limitation of cost and technology. Usually, it can be obtained by super-resolution reconstruction (downscale) from low-resolution DEM. However, the accuracy of the DEM generated by conventional downscale methods is insufficient. With the development of image downscale, convolutional neural network(CNN) has achieved success. To improve DEM accuracy, a very deep convolutional networks super-resolution method(VDSR) was designed to reconstruct the terrace DEM with obvious undulation characteristics. The deep neural network was used to learn nonlinear mapping between high-resolution DEM and low-resolution DEM, at the same time, residual learning method were used to reduce training difficulty. In order to compare, bicubic interpolation method, sparse mixed estimation method and VDSR method were used to reconstruct the DEM and slope. The slope data were extracted from the DEM results. The mean value of DEM difference of three methods were 0.41 m, 0.34 m and 0.34 m, respectively. The RMSE of DEM were 0.594 5 m, 0.571 5 m and 0.486 9 m, respectively. The mean value of slope difference of three methods were 3.02°, 2.04° and 1.99°, respectively. The RMSE of slope were 3.649 8°, 3.136 0° and 2.738 7°, respectively. The running time were 0.052 s, 663.39 s and 2.16 s, respectively. By comprehensive comparison, for 10 m, 20 m and 40 m DEM, the result showed that VDSR method had great advantage in spatial distribution, error and running time, and it was suitable for super-resolution reconstruction in areas with complex terrain such as terrace.

Key words: mountain area; digital elevation model; super-resolution reconstruction; slope; deep residual convolution neural network

收稿日期: 2020-03-14 修回日期: 2020-04-16

基金项目: 国家自然科学基金项目(41771315、41501294)、国家重点研发计划项目(2017YFC0403203)和西北农林科技大学博士启动基金项目(Z1090219191)

作者简介: 张宏鸣(1979—),男,教授,博士,主要从事空间大数据管理与区域土壤侵蚀评价研究,E-mail: zhm@nwsuaf.edu.cn

0 引言

数字高程模型 (Digital elevation model, DEM)^[1] 是将地表高程用数字形式表达的有序阵列, 具有丰富的地学应用价值^[2], 被广泛应用于水文分析、流域特征提取、城市规划等方面。DEM 的精度决定了地学信息提取及分析的准确度^[3]。受测量成本和技术限制, 高精度的 DEM 较难获得^[4-5]。卫星遥感是近年来获取高精度 DEM 的较好方法。采用航空摄影、SAR (Synthetic aperture radar)、光探测等技术获取 DEM, 在时间、成本和工作量上有着较大的优势^[6]。无人机遥感技术由于设备体积小、操作简单、灵活性强等优势而被广泛应用于航空遥感、地面遥感、精准农业领域^[7-8]。随着多种数据获取技术的发展, 同一地区的遥感影像越来越多, 具有多时相、多光谱、多分辨率的特点^[9]。为了利用多源数据的互补性和合作性提取更加丰富的信息, 学者们对数据融合技术进行了研究^[10-11]。然而, 由于安全性和保密性等原因, 获取多源数据极为困难。近年来, 对低分辨率 DEM 重构直接获取高分辨率 DEM 的超分辨率方法具有很强的可行性^[12]。

DEM 超分辨率方法的研究由来已久^[13-16]。随着计算机技术和人工智能的发展, 研究发现, 基于学习的方法能够有效利用高效能计算机硬件的优势, 抽象地学习到高低分辨率数据之间的映射关系, 从而提高 DEM 精度^[17]。文献[18]提出了非局部相似性的方法, 利用测试区域同其他相似区域的关系重构 DEM 数据。文献[19]使用稀疏混合估计法对 10、20、40 m 的 DEM 进行重构变换, 研究了超分辨率对黄土高原 DEM 坡度的影响。文献[20]设计了一种 HNN 神经网络, 对 20、60、90 m 的格网 DEM 进行超分辨率重构, 进一步提高了格网 DEM 的重构精度。文献[21]分析了几种卷积神经网络方法对 DSM 重构结果的影响, 证明对于子像素级的 DSM, 超分辨率方法更易获取更高精度的数据。文献[22]提出了一种全卷积神经网络算法, 对卫星高程数据和实地测绘数据之间的映射关系进行研究, 提升了公共 DEM 的精度。传统端到端方法的网络模型设计简单, 且运算快捷^[23]。为了进一步提高结果的精度, 有学者证明适度增加卷积网络层数可获得很好的效果^[24]。但是, 网络层数的增加意味着更大的计算量和更多的时间消耗, 不适用于实时数据处理。有学者提出了残差学习思路, 在网络训练时, 只进行差值计算^[25]。由于 DEM 高程往往较高, 相对于普通图像在这种训练思路下获益更大。因此, 深层残差卷积神经网络可能是提升 DEM 精度的

有效方法。

梯田 DEM 在农业领域应用广泛。低分辨率梯田 DEM 的田坎、田埂等纹理过于模糊, 不能准确表达实际地形特征^[26]。通过超分辨率重构对梯田 DEM 的格网空间进行重新分配, 能够获得更加精细和微观的梯田地理信息表达^[27-28]。本文利用无人机梯田 DEM 数据, 采用深层残差卷积神经网络对低分辨率梯田 DEM 进行重构, 获取高分辨率 DEM, 并提取坡度。将高程结果和坡度结果分别与双立方插值法、稀疏混合估计法的结果进行对比, 以证明本文方法具有更强的学习数据和获取地形特征的能力, 以期为梯田 DEM 超分辨率重构方法的研究提供思路。

1 研究方法

1.1 研究区概况

以渝中地区龙泉乡黄土丘陵区典型旱梯田区为实验区, 地理坐标为 104°10′58″~104°19′51″E, 35°34′4″~35°40′56″N, 具有一定的代表性。该实验区 DEM 数据及其所在的黄土高原位置如图 1 所示, 原始分辨率为 0.5 m, 高程为 1 951.03~2 545.55 m。

由于不同区域数据高程差距较大。为了减小误差, 使训练集适应大部分梯田数据。选取具有不同高程特点的实验样区 1、2、3 为训练样本集。其中, 实验样区 1 整体高程较高, 实验样区 2 整体高程适中, 实验样区 3 整体高程较低。选取面积较大的实验样区 4 作为测试样本, 地势整体起伏较大, 覆盖高程范围广, 能测试出更准确结果。样本区域如图 2 所示。




图 1 甘肃省榆中县龙泉乡 DEM 及其所在黄土高原位置图
Fig. 1 DEM and location of study area

1.2 重构算法

卷积神经网络是一种基于卷积运算的前馈神经网络, 通过对大量样本的有监督学习, 将数据抽象化, 并将特征提取的过程隐含在网络中^[29]。深层的卷积神经网络结构可以加深层与层之间的联系, 更好地学习到复杂的网络模型, 提高网络对高频信息的表达能力^[30]。本文将输入数据预插值到重构尺




图2 样本区域
Fig.2 Sample areas

寸,通过对数据的训练,学习高低分辨率数据之间的映射关系,进而重构出高频信息来达到重构效果。

1.2.1 算法流程

整个算法流程可描述为:①对原始训练样本进行重采样,生成低分辨率数据集,将二者混合得到高低分辨率样本集。②对高低分辨率样本集进行预处理,完成训练数据集准备。③控制神经网络结构,生成深层残差卷积神经网络。④对训练数据进行特征提取,选取合适的损失函数对其训练得到最优模型。⑤输入测试数据,使用最优模型对其进行重构。⑥将输出的数据转换为 DEM 数据格式(ASCII 码)。⑦从高分辨率 DEM 数据中提取坡度。整体算法流程图如图 3 所示。




图3 算法流程图
Fig.3 Algorithm flow chart

1.2.2 网络结构

使用一种深层的残差网络^[31]进行训练,这种残

差学习方法可以缓解加深网络层数带来的梯度爆炸问题,并有效减少整个网络的参数。采用一种跳跃连接结构,假设 y 为映射目的层, x 为输入层,则残差函数表达为

$$F(x) = y - x \tag{1}$$

此时,原始函数可定义为

$$y = F(x) + x \tag{2}$$

在每一次卷积操作后对输出进行补零操作,保证输入输出数据尺寸相同,忽略偏差值,则整个残差网络可用数学公式表达为

$$H(x) = F(x, \{W_i\}) + x \tag{3}$$

整个网络共有 22 层。第 1 层处理输入数据特征,中间 20 层每层包含 64 个 $3 \times 3 \times 64$ 的卷积核,最后一层包含 1 个 $3 \times 3 \times 64$ 的卷积核。将原始低分辨率 DEM 进行双立方插值预处理到目标尺寸,输入模型中得到高分辨率 DEM。

用 ReLU 激活函数^[32]对每次卷积的结果进行非线性拟合,相比于其他激活函数,由于其一定的稀疏性,能更好地拟合训练数据。同时,其单侧抑制性实现了对信号的部分响应,提高了训练速度,公式为

$$\sigma(x) = \max(0, x) \tag{4}$$

1.2.3 损失函数

文献 [33] 表明使用平均绝对误差 (Mean absolute error, MAE) 损失函数训练得到的结果较好,故本文使用 MAE 损失函数进行 DEM 数据训练。

用均方根误差 (Root mean square error, RMSE) 作为重构准确性评价标准,值越小,说明重构后的 DEM 结果相对于真实数据的差距越小,更加符合真实梯田地形地貌特征。

2 实验结果与分析

为了更清楚地展示重构结果,本文截取了局部 DEM 及其坡度计算结果,将深层残差网络法 (Very deep convolutional networks super-resolution, VDSR) 结果分别与双立方插值法 (Bicubic interpolation, CUBIC)^[34]、稀疏混合估计法 (Sparse mixed estimation, SME)^[35]进行对比评价。用作差法、频率曲线法和 RMSE 指标对结果进行统计分析,进一步验证重构结果。

实验中对原始测试数据进行双立方插值之后得到对应的 10、20、40 m 的低分辨率数据。将该 3 种分辨率的数据采用不同方法重构成相应的高分辨率数据 (5、10、20 m),从重构后的数据中提取坡度数据并与实际坡度数据进行对比。40 m 到 20 m 的重构称为 R20,20 m 到 10 m 的重构称为 R10,10 m 到 5 m 的重构称为 R05。

对于深层残差卷积神经网络训练方法,将高低分辨率 DEM 数据进行切割和旋转操作,混合所有样本共 340 个,挑选 30 个梯田特征较明显的数据作为测试集。设置基本学习率为 1×10^{-5} ,模型使用 Adam 优化方法,设定 $\beta_1 = 0.9, \beta_2 = 0.999, \varepsilon = 1 \times 10^{-8}$ 。训练 134 000 次得到最佳模型。实验使用 Caffe、Matconvnet 实现,用 NVIDIA M4000 GPU 进行训练。

2.1 DEM 空间分布结果

为了更好地展示实验结果,将测试样本(实验样区 4)的典型梯田区域局部放大。3 种方法生成的不同分辨率 DEM 和实际高分辨率 DEM (Origin digital elevation model, OD) 如图 4 所示,从上到下的 3 行数据依次为 R05、R10、R20 的计算结果,颜色由绿变红表示高程由低变高。




图 4 重构后的 DEM 数据计算结果

Fig. 4 DEM calculation results after reconstruction

2.2 坡度空间分布结果

从 DEM 数据中提取坡度结果,由 3 种方法生成的不同分辨率 DEM 提取到的坡度结果和实际高分辨率坡度数据 (Origin slope, OS) 如图 5 所示,3 行数据从上到下分别为 R05、R10、R20 的计算结果,颜色由绿到红表示坡度由平缓变陡峭。

随着分辨率的升高,3 种方法提取到的坡度整体精度得到提升,并且与实际结果逐渐接近,其中深层残差网络法在 3 种分辨率条件下均最好。

在不同的分辨率情况下,深层残差网络法提取结果在空间分布上明显好于其他方法,尤其在较为平坦区域(田面)和较为陡峭区域(田埂)的重构结果,能够提取到空间分布更加精确的纹理效果。

在分辨率较低情况下,深层残差网络法仍能保持相对较好的空间线条。




图 5 重构后的坡度结果

Fig. 5 Slope calculation results after reconstruction

2.3 计算结果统计分析

以 R05 为例,将双立方插值法、稀疏混合估计法、深层残差网络法提取到的 DEM 数据分别同实际 5 m DEM 数据作差,结果如图 6 所示。




图 6 重构后的 DEM 差值计算结果

Fig. 6 DEM difference results after reconstruction

双立方插值法、深层残差网络法的 DEM 差值结果表现为田坎、陡坡处误差较大,田面处误差较小。稀疏混合估计法出现了误差分布不一的情况,与数据本身的相关性并不大。

以 R05 为例,将 3 种方法提取到的坡度计算结果分别同实际 5 m 坡度数据作差。结果如图 7 所示。图像颜色绿色区域占比越大,该处理方法误差越小,效果越好。




图 7 重构后的坡度差值计算结果

Fig. 7 Slope difference results after reconstruction

从图 7 结果可以看出,双立方插值法、深层残差网络法在田坎、陡坡处误差较大,而田面处重构效果

较好。稀疏混合估计法的误差并未集中在某一类区域,整体分布较为分散,在田面处也出现了效果不好的现象。

深层残差网络法的坡度误差很少会出现较长的连续条状纹理,其误差均集中在坡度较高的梯田区域,面积占比更大的田面区域绝大多数重构误差低于 5° 。

将各方法结果同实际结果作差,计算 DEM 差值频率和 DEM 累计差值频率分布如图 8 所示。深层残差网络法的高程误差在 0.5 m 以内的区域占到了 98.3%,稀疏混合估计法的高程误差在 0.5 m 以内的区域占到了 97%,与双立方插值法接近。




图 8 DEM 差值频率及累计差值频率曲线
Fig. 8 Frequency curves and cumulative frequency curves of DEM difference

将各方法结果同实际结果作差,计算坡度差值频率和坡度累计差值频率分布如图 9 所示。从曲线图中可以看到,3 种方法均为深层残差网络法效果最好。与实际结果相比,深层残差网络法 95% 以上的区域误差在 5° 以内,稀疏混合估计法 93% 区域误差在 5° 以内,而双立方插值法的这个比例在 90% 以下。

根据表 1 的差值结果分析,3 种方法的高程和坡度误差最小值均为 0。由最大值来看,深层残差网络法的高程误差和坡度误差的最大值最小,而其他方法会造成误差局部过大情况。就高程平均值来看,深层残差网络法与稀疏混合估计法相同,好于双




图 9 坡度差值频率及累计差值频率曲线
Fig. 9 Frequency curves and cumulative frequency curves of slope difference

立方插值法。深层残差网络法在坡度误差平均值上好于稀疏混合估计法和双立方插值法。

由表 2 的 RMSE 结果可知,深层残差网络法在高程和坡度结果上与实地数据偏离最小。

表 1 差值结果
Tab. 1 Difference result

数据类型	参数	CUBIC	SME	VDSR
DEM/m	平均值	0.41	0.34	0.34
	最大值	9.20	12.50	7.90
	最小值	0	0	0
坡度/($^{\circ}$)	平均值	3.02	2.04	1.99
	最大值	37.14	43.33	33.93
	最小值	0	0	0

表 2 RMSE 结果
Tab. 2 RMSE result

数据类型	CUBIC	SME	VDSR
DEM/m	0.594 5	0.571 5	0.486 9
坡度/($^{\circ}$)	3.649 8	3.136 0	2.738 7

根据耗时时间分析,稀疏混合估计法处理时间为 663.39 s,而深层残差网络法处理时间仅为 2.16 s,较稀疏混合估计法提升了 300 多倍。双立方插值法计算较为简单,处理时间为 0.052 s,消耗时间最少。深层残差网络法在处理时间上具有较大优势。

3 结论

(1)针对常规的 DEM 超分辨率重构方法精度不高、难以满足实际需要的问题,提出一种卷积神经网络方法对 DEM 进行超分辨率重构,并分别在 DEM 结果和坡度结果上与传统插值法(双立方插值法)和浅层学习法(稀疏混合估计法)进行对比分析。通过实验验证,本文方法在 DEM 上的差值平均值和 RMSE 结果分别为 0.34、0.486 9 m,较其他方法均有所提升。在坡度上的差值平均值和 RMSE 结

果分别为 1.99°、2.738 7°,比其他方法的地形数据结果更加接近原始地形。处理时间仅为 2.16 s,比浅层学习法提升 300 多倍。

(2)在多源数据难以获得的现实情况下,利用多分辨率 DEM 数据之间信息的互补性,结合适当的深层网络设计,可以更好地映射原始数据与结果数据之间的关系。采用残差网络学习方法,可以降低训练难度。深层残差网络方法能够有效提高 DEM 精度,为获取高分辨率 DEM 提供了新的思路。

参 考 文 献

[1] ZHANG H, YANG Q, LI R, et al. Extension of a GIS procedure for calculating the RUSLE equation LS factor[J]. Computers & Geosciences, 2013, 52: 177 – 188.

[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. (in Chinese)

[3] 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. TANG Guoan, NA Jiaming, CHENG Weiming. Progress of digital terrain analysis on regional geomorphology in China[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(10): 1570 – 1591. (in Chinese)

[4] WANG X, HOLLAND D M, GUDMUNDSSON G H. Accurate coastal DEM generation by merging ASTER GDEM and ICESat/GLAS data over Mertz Glacier, Antarctica[J]. Remote Sensing of Environment, 2018, 206: 218 – 230.

[5] ZHANG H, YANG J, BAARTMAN J E, et al. Quality of terrestrial data derived from UAV photogrammetry: a case study of Hetao irrigation district in northern China[J]. International Journal of Agricultural and Biological Engineering, 2018, 11(3): 171 – 177.

[6] LAKSHMI S E, YARRAKULA K. Review and critical analysis on digital elevation models[J]. Geofizika, 2018, 35(2): 129 – 157.

[7] 韩文霆, 张立元, 牛亚晓, 等. 无人机遥感技术在精量灌溉中应用的研究进展[J/OL]. 农业机械学报, 2020, 51(2): 1 – 14. HAN Wenting, ZHANG Liyuan, NIU Yaxiao, et al. Review on UAV remote sensing application in precision irrigation[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 1 – 14. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2002001&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2020.02.001. (in Chinese)

[8] 孙刚, 黄文江, 陈鹏飞, 等. 轻小型无人机多光谱遥感技术应用进展[J/OL]. 农业机械学报, 2018, 49(3): 1 – 17. SUN Gang, HUANG Wenjiang, CHEN Pengfei, et al. Advances in UAV-based multispectral remote sensing applications[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(3): 1 – 17. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20180301&flag=1. DOI: 10.6041/j.issn.1000-1298.2018.03.001. (in Chinese)

[9] 李盛阳, 张万峰, 杨松. 多源高分辨率遥感影像智能融合[J]. 遥感学报, 2017, 21(3): 415 – 424. LI Shengyang, ZHANG Wanfeng, YANG Song. Intelligence fusion method research of multisource high-resolution remote sensing images[J]. Journal of Remote Sensing, 2017, 21(3): 415 – 424. (in Chinese)

[10] BAGHERI H, SCHMITT M, ZHU X. Fusion of multi-sensor-derived heights and OSM-derived building footprints for urban 3D reconstruction[J]. ISPRS International Journal of Geo-Information, 2019, 8(4): 193.

[11] SHEN H, MENG X, ZHANG L. An integrated framework for the spatio-temporal-spectral fusion of remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(12): 7135 – 7148.

[12] 岳林蔚. 多源多尺度 DEM 数据融合方法与应用研究[D]. 武汉: 武汉大学, 2017. YUE Linwei. Research on DEM fusion blending multi-source and multi-scale elevation data[D]. Wuhan: Wuhan University, 2017. (in Chinese)

[13] 于浩, 杨勤科, 张晓萍, 等. 基于小波多尺度分析的 DEM 数据综合及尺度转换[J]. 地理与地理信息科学, 2009, 25(4): 12 – 16. YU Hao, YANG Qinke, ZHANG Xiaoping, et al. A study of DEM generalization based on wavelet analysis and it scale transformation[J]. Geography and Geo-information Science, 2009, 25(4): 12 – 16. (in Chinese)

[14] 郭兰勤, 杨勤科, 胡洁, 等. 基于分形的中低分辨率坡度降尺度变换方法研究[J]. 西北农林科技大学学报(自然科学版), 2011, 39(12): 173 – 180. GUO Lanqin, YANG Qinke, HU Jie, et al. Research on method of re-scaling coarser resolution slope based on fractal analysis approach[J]. Journal of Northwest A&F University(Natural Science Edition), 2011, 39(12): 173 – 180. (in Chinese)

- [15] 王雷, 龙永清, 杨勤科. 重采样方法对 DEM 数据质量的影响[J]. 水土保持通报, 2016, 36(4): 72–77.
WANG Lei, LONG Yongqing, YANG Qinke. Effects of resampling method on data quality of DEMs[J]. Bulletin of Soil and Water Conservation, 2016, 36(4): 72–77. (in Chinese)
- [16] TAN M L, RAMLI H P, TAM T H. Effect of DEM resolution, source, resampling technique and area threshold on SWAT outputs[J]. Water Resources Management, 2018, 32(14): 4591–4606.
- [17] XU Z, CHEN Z, YI W, et al. Deep gradient prior network for DEM super-resolution: transfer learning from image to DEM[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 150: 80–90.
- [18] XU Z, WANG X, CHEN Z, et al. Nonlocal similarity based DEM super resolution[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 110: 48–54.
- [19] 张宏鸣, 宋泽鲁, 杨江涛, 等. DEM 超分辨率重构对梯田坡度提取的影响研究[J/OL]. 农业机械学报, 2017, 48(1): 112–118, 138.
ZHANG Hongming, SONG Zelu, YANG Jiangtao, et al. Influence of DEM super-resolution reconstruction on terraced field slope extraction[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(1): 112–118, 138. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170115&flag=1. DOI: 10.6041/j.issn.1000-1298.2017.01.015. (in Chinese)
- [20] NGUYEN Q M, NGUYEN T T H, LA P H, et al. Downscaling gridded DEMs using the hopfield neural network[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(11): 4426–4437.
- [21] ZHANG Y, ZHENG Z, LUO Y, et al. A CNN-based subpixel level DSM generation approach via single image super-resolution[J]. Photogrammetric Engineering & Remote Sensing, 2019, 85(10): 765–775.
- [22] 谢洪亮. 基于卷积神经网络的数字高程分辨率提高方法[J]. 地理空间信息, 2020, 18(1): 28–31.
XIE Hongliang. Super resolution of digital terrain map based on convolutional neural network[J]. Geospatial Information, 2020, 18(1): 28–31. (in Chinese)
- [23] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295–307.
- [24] KIM J, KWON L J, MU L K. Accurate image super-resolution using very deep convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646–1654.
- [25] GAO M, HAN X H, LI J, et al. Image super-resolution based on two-level residual learning CNN[J]. Multimedia Tools and Applications, 2020, 79(7): 4831–4846.
- [26] ARGUDO O, CHICA A, ANDUJAR C. Terrain super-resolution through aerial imagery and fully convolutional networks[C]//Computer Graphics Forum. Wiley Online Library, 2018: 101–110.
- [27] 万昌君, 吴小丹, 林兴稳. 遥感数据时空尺度对地理要素时空变化分析的影响[J]. 遥感学报, 2019, 23(6): 1064–1077.
WAN Changjun, WU Xiaodan, LIN Xingwen. Impact of spatial and temporal scales of remote sensing data on the spatiotemporal change in geographic elements[J]. Journal of Remote Sensing, 2019, 23(6): 1064–1077. (in Chinese)
- [28] 张亚南. DEM 分辨率确定与尺度转换方法研究[D]. 南京: 南京师范大学, 2014.
ZHANG Ya'nan. Research on DEM resolution determination and scaling conversion methods[D]. Nanjing: Nanjing Normal University, 2014. (in Chinese)
- [29] 徐泽楷. 稀缺样本下基于深度学习的图像超分辨率方法研究[D]. 武汉: 华中科技大学, 2019.
XU Zekai. Research on deep learning based image super resolution with sparse samples[D]. Wuhan: Huazhong University of Science & Technology, 2019. (in Chinese)
- [30] 唐永亮. 单幅图像超分辨率重建方法研究[D]. 重庆: 重庆大学, 2018.
TANG Yongliang. Research on single image super-resolution reconstruction method[D]. Chongqing: Chongqing University, 2018. (in Chinese)
- [31] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [32] HANIN B. Universal function approximation by deep neural nets with bounded width and relu activations[J]. Mathematics, 2019, 7(10): 992.
- [33] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]//30th IEEE Conference on Computer Vision and Pattern Recognition Workshops, CVPRW 2017. Honolulu, HI, United States. IEEE Computer Society, 2017: 1132–1140.
- [34] AWADA H, CIRAOLLO G, MALTESE A, et al. Assessing the performance of a large-scale irrigation system by estimations of actual evapotranspiration obtained by Landsat satellite images resampled with cubic convolution[J]. International Journal of Applied Earth Observation and Geoinformation, 2019, 75: 96–105.
- [35] MALLAT S, YU G. Super-resolution with sparse mixing estimators[J]. IEEE Transactions on Image Processing, 2010, 19(11): 2889–2900.