

# 深度残差频率自适应的 DEM 超分辨重建<sup>①</sup>



李智杰, 米德源, 李昌华, 张 颖, 董 珮

(西安建筑科技大学 信息与控制工程学院, 西安 710055)

通信作者: 李昌华, E-mail: [lch304502@126.com](mailto:lch304502@126.com)

**摘要:** 目前超分辨率重建技术运用于诸多场景, 但对于数字高程模型 (digital elevation model, DEM) 的重建存在许多挑战, 针对无法充分利用 DEM 复杂地形特征导致的细节缺失和失真问题, 提出了深度残差频率自适应的 DEM 超分辨重建模型, 由多个高低频特征提取模块组成残差网络结构, 提升对 DEM 特征的整体感知能力, 并加入频率选择特征提取模块, 增强对复杂地形特征的识别和捕捉能力, 其次在模型中加入了空洞空间金字塔池化, 通过融合多尺度信息, 改善重建质量并充分保留地形特征的细节和结构, 最终在梯度域和高度域双重约束下完成超分辨率重建。实验结果表明, 在以两种精度的陕西秦岭高程图作为实验数据下, 深度残差频率自适应 DEM 超分辨率模型相较于其他先进模型, 在各个指标上均取得了提升, 重建后的 DEM 细节更加丰富、纹理更加清晰。

**关键词:** 数字高程模型; 残差网络; 空洞空间金字塔池化; 超分辨率重建

引用格式: 李智杰, 米德源, 李昌华, 张颖, 董玮. 深度残差频率自适应的 DEM 超分辨重建. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9692.html>

## Deep Residual Frequency-adaptive DEM Super-resolution Reconstruction

LI Zhi-Jie, MI De-Yuan, LI Chang-Hua, ZHANG Jie, DONG Wei

(School of Information and Control Engineering, Xi'an University of Architectural Science and Technology, Xi'an 710055, China)

**Abstract:** Currently, super-resolution reconstruction technology is applied in various fields. However, digital elevation model (DEM) reconstruction presents numerous challenges. To address the issues of detail loss and distortion caused by inadequate utilization of complex terrain features in DEM, this study proposes a deep residual frequency-adaptive DEM super-resolution reconstruction model. The model consists of multiple high and low-frequency feature extraction modules forming a residual network structure, enhancing the overall perception of DEM features. Additionally, a frequency selection feature extraction module is integrated to improve the identification and capture of complex terrain features. The model also incorporates atrous spatial pyramid pooling, which merges multi-scale information to enhance reconstruction quality and retain detailed terrain features and structures. Final super-resolution reconstruction is completed under dual constraints in the gradient and height domains. Experimental results demonstrate that using elevation maps of the Qinling Mountains in Shaanxi with two different accuracies as test data, the deep residual frequency-adaptive DEM super-resolution model outperforms other advanced models across various metrics. Reconstructed DEMs exhibit richer details and clearer textures.

**Key words:** digital elevation model (DEM); residual network; atrous spatial pyramid pooling (ASPP); super-resolution reconstruction (SRR)

<sup>①</sup> 基金项目: 国家自然科学基金(51878536); 陕西省住房和城乡建设科技计划(2020-K09); 陕西省教育厅协同创新中心项目(23JY038)

收稿时间: 2024-05-24; 修改时间: 2024-06-17; 采用时间: 2024-06-26; csa 在线出版时间: 2024-10-31

数字高程模型 (digital elevation model, DEM) 是一种地理信息系统 (GIS) 中常用的地形数据模型, DEM 在各种地理分析中起着重要作用, 广泛应用于地形分析<sup>[1]</sup>、水文建模<sup>[2]</sup>、地形辅助导航<sup>[3]</sup>和环境模拟<sup>[4]</sup>等领域。DEM 精度越高对于地理分析的结果越准确, 因此如何获得高分辨率 DEM 已成为研究热点<sup>[5-9]</sup>。采用车载激光雷达测量<sup>[10]</sup>、航空摄影测量<sup>[11]</sup>和卫星影像测量<sup>[12]</sup>等方法, 都是直接获取 DEM 的方法, 但耗时耗力, 对于部分地方并不适合使用大规模的采集方式。并且随着 DEM 测量方式的增多, 对同一地区的 DEM 也越来越多, 呈多分辨率和多时相的特点, 学者们已经开始探索利用多源 DEM 进行数据融合以提高 DEM 分辨率<sup>[13,14]</sup>。

然而, 由于部分地区 DEM 的保密性, 多源 DEM 的获取存在一定困难。因此, 目前主流的方法是对低分辨率 DEM 进行超分辨率重建 (super-resolution reconstruction, SRR), 从算法原理上分为基于插值、基于重建和基于学习这 3 类。其中基于插值的方法 (如最邻近插值、双线性插值和三次样条插值) 无法准确推测原始高分辨率图像的细节信息, 导致丢失地形尖锐边缘和细微变化, 并产生不真实的伪影或平滑效果, 缺乏细节和清晰度。而基于重建的方法 (如凸集投影法<sup>[15]</sup>、迭代反投影法<sup>[16]</sup>和最大后验估计法<sup>[17]</sup>) 受限于假设的模型, 在重建过程中与实际情况不一致, 导致细节损失和无法处理复杂的结构, 重建后可能模糊、失真或产生伪影。

基于学习的图像超分辨率算法与前两种类型有显著区别, 通过学习高分辨率图像与对应低分辨率图像之间的映射关系并计算特征信息来重建高分辨率图像。并且随着深度学习的发展, 出现了一种新的超分辨率图像重建方法: 将卷积神经网络 (convolutional neural network, CNN) 应用到超分辨率任务中, 2016 年, Chen 等人<sup>[18]</sup>在 CNN 的基础上, 通过最小化误差的优化方法输出高分辨率的 DEM, 该方法重建得到的 DEM 和传统插值方法相比取得了更好的效果。2018 年, Xu 等人<sup>[19]</sup>利用深度卷积网络结合迁移学习, 成功将自然图像学习的知识迁移到 DEM 超分辨率重建领域, 实现在少量 DEM 情况下获得高精度结果。2020 年, Jiao 等人<sup>[20]</sup>, 提出了基于深度残差网络的 DEM 超分辨率重建模型, 该模型通过最小化重建误差来优化模型, 从而提高 DEM 的分辨率和精度。2022 年, Lin 等人<sup>[21]</sup>, 介绍了一个结合内部和外部学习的 DEM 超分辨率重建模型, 该模型利用 DEM 数据的内部先验知识和外部图像数据集的

学习, 以提升重建后 DEM 的质量和细节。2023 年, Zhou 等人<sup>[22]</sup>, 将地形特征与 CNN 进行结合, 介绍了一种基于多地形特征的超分辨率深度模型, 从矢量和栅格地形特征的角度出发, 提高了 DEM 整体精度和保留地形特征的优势。

针对数字高程模型超分辨重建中存在的地理结构细节缺失问题以及传统基于 CNN 的方法的局限性, 本文提出了深度残差频率自适应 DEM 超分辨率模型 (deep residual frequency-adaptive DEM super-resolution model, DRFA-SR), 首先利用边缘检测算子得到 DEM 梯度图, 解决将 DEM 作为二维图像拓展, 所导致高程特征与 RGB 特征几何线索差异问题, 并加入高低频特征提取模块 (high-low frequency feature extraction block, HIFEB) 通过频率选择特征提取块 (frequency-selective feature extraction block, FreqSelect), 获取 DEM 高低频特征信息, 为后续 DEM 重建提供丰富的信息, 然后由空洞空间金字塔池化 (atrous spatial pyramid pooling, ASPP) 输出最终特征图。

本文的主要工作如下:

(1) 提出了一个深度残差频率自适应 DEM 超分辨率重建模型, 通过使用梯度图作为输入数据来获取 DEM 中高频细节并避免将 DEM 作为二维图像拓展所引起的误差。

(2) 通过引入 HIFEB 和 ASPP 模块有效地提取 DEM 中的高低频信息, 同时降低了模型的复杂性, 提高了超分辨率重建的准确性和效率。

(3) 实验表明, 本文提出的 DRFA-SR 与其他目前先进模型对比, 在不同缩放因子下超分辨率实验上各个指标上均取得了优势。

## 1 研究方法

### 1.1 深度残差频率自适应 DEM 超分辨率模型

DRFA-SR 由梯度提取模块、浅层特征提取模块、深层特征提取模块、超分辨率重建模块和高度域重建模块组成, 如图 1 所示。

(1) 梯度提取模块

将低分辨率 DEM  $D_{LR} \in R^{H \times W \times 1}$  通过边缘检测 Prewitt 算子得到低分辨率 DEM 梯度  $D_{LR}^t \in R^{H \times W \times 1}$ , 并作为输入, 过程如下:

$$D_{LR}^t = \sqrt{(D_{LR})_x^2 + (D_{LR})_y^2} \quad (1)$$

其中,  $(D_{LR})_x$  和  $(D_{LR})_y$  分别为水平方向梯度图和竖直方向梯度图.

### (2) 浅层特征提取模块

该模块采用  $3 \times 3$  卷积进行浅层特征提取, 由式(2)所示:

$$F_1 = \text{Conv}(D_{LR}^t) \quad (2)$$

其中,  $F_1 \in R^{H \times W \times C}$  为梯度图的浅层特征,  $C$  为特征图通道数, 利用卷积可以使网络具备浅层特征提取能力, 能对梯度图中的低频信息进行特征提取.

### (3) 深层特征提取模块

将得到的  $F_1$  特征进行深层提取, 深层特征提取模块含有  $M$  个高低频特征提取残差块 (HIFEB) 和一个空

洞空间金字塔池化块 (ASPP). 最终特征图  $F_E$  为:  $F_1$  经过  $M$  个 HIFEB 和一个 ASPP 逐层提取得到, 该过程的输出可以表示为:

$$\begin{cases} F_{k+1} = \text{HIFEB}(F_k), k \in 1, 2, \dots, M-1 \\ F_E = \text{ASPP}(F_{k+1}) \end{cases} \quad (3)$$

### (4) 超分辨率重建模块

超分辨率重建模块由两个卷积块、一个 ReLU 函数和一个亚像素卷积层构成. 在重建高分辨率梯度图时, 将  $F_E$  和  $F_1$  输入到超分辨率重建模块中进行重建, 如下所示:

$$D_{SR}^t = f_{rec}(F_1 + F_E) \quad (4)$$

其中,  $f_{rec}(\cdot)$  是重建模块函数.

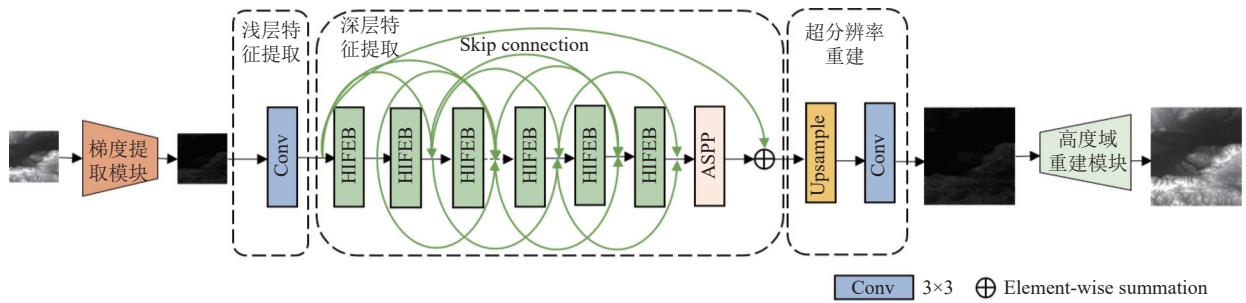


图 1 模型结构

### (5) 高度域重建模块

利用重建后高分辨率梯度图  $D_{SR}^t$ , 在高度域下重建出高分辨率 DEM  $D_{SR}$ , 如图 2 所示, 过程如下:

$$D_{SR} = \min_{D_{SR}} \left\{ \sum_{i=1}^n |D_{LR} - D_{LR} \downarrow|^2 + \mu \sum_{i=1}^n |D_{SR}^t - \tilde{D}_{SR}^t|^2 \right\} \quad (5)$$

并采用梯度下降算法 (gradient descent), 得出最优  $D_{SR}$ .

## 1.2 高低频特征提取模块

考虑到 DEM 空间信息极为复杂, 分辨率在水平和垂直方向上的变化影响着地形特征的表达, 使得 DEM 中微观地表的沟壑、悬崖等在数据呈中现出局部突出的形态, 然而, 在处理复杂地形会导致细节丢失、模糊和失真. 因此, 为了更好地捕获地形数据的细节和结构特征, 提高重建质量, 引入了高低频特征提取残差块, 如图 3 所示.

在残差神经网络中, 特征图之间的关系可以表示为:

$$Y = y + G \quad (6)$$

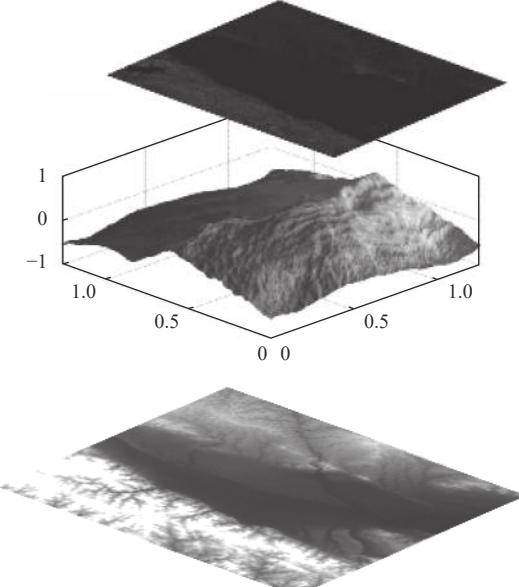


图 2 基于高度域重建

其中,  $Y$ 、 $y$ 、 $G$  分别表示最终特征图、输入特征图和残差特征图. 在残差块中,  $y$  过一系列的卷积操作和非线性激活函数后得到了  $G$ . 由式 (6) 可以得到在输入特

征图不变的情况下, 用于重建特征图需提升的残差特征图, 如式(7)所示:

$$G = Y - y \quad (7)$$

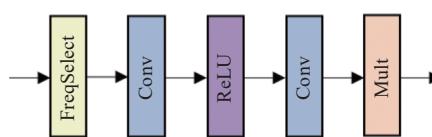


图3 HIFEB结构

$G$ 是由当前一次残差块的输出作为下一次残差块的输入经过 $n$ 次最后一次输出的残差特征图,  $G_i$ 是当前该残差块的输出,  $y_i$ 是当前该残差块的输入,  $i$ 为残差块的个数, 其中 $F$ 表示残差块内的操作,  $\theta_i$ 表示第*i*个残差块内卷积层的参数,  $L$ 代表卷积层的总数, 如式(8)所示:

$$G_i = y_i + F(y_i; \theta_i W_{i:L}; B_{i:L}), i = 1, 2, \dots, N \quad (8)$$

DEM包含丰富的高频特征和低频特征, 在残差块内部引入FreqSelect, 通过多尺度特征提取和残差学习, 有效地保留和重建DEM的细节和结构信息, 如图4所示.

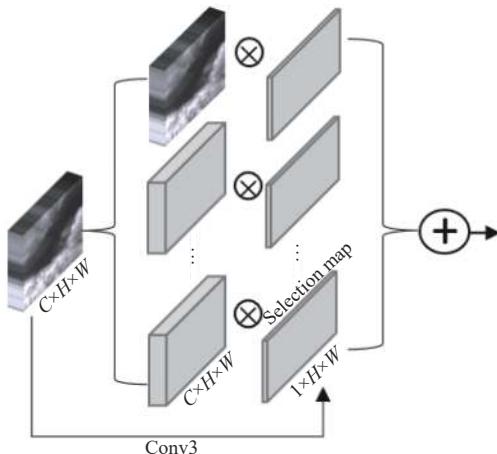


图4 FreqSelect结构

在FreqSelect中, 在傅里叶域中通过应用不同的掩码将DEM输入特征图 $y$ 分解为不同的频率带, 如下:

$$y = \mathcal{F}^{-1}(M_b \cdot \mathcal{F}(X)) \quad (9)$$

其中,  $\mathcal{F}$ 表示快速傅里叶变换,  $\mathcal{F}^{-1}$ 表示逆快速傅里叶变换,  $M_b$ 是一个二进制掩码, 用于提取相应的频率带:

$$\begin{cases} 1, & \text{if } \phi_b \leq k \leq \phi_{b+1} \\ 0, & \text{otherwise} \end{cases} \quad (10)$$

其中,  $\phi_b, \phi_{b+1}$ 来自预定义的频率阈值集合 $\{0, \phi_1, \phi_2, \dots, \phi_{b-1}, \frac{1}{2}\}$ .

随后, FreqSelect在空间上动态地重新加权不同频率带中的频率成分, 以在重建过程中更好地平衡高低频特征. 其公式为:

$$y' = \sum_{b=0}^{B-1} A_b(i, j) X_b(i, j) \quad (11)$$

其中,  $y'$ 是经过FreqSelect处理后的特征图,  $A_b \in R^{H \times W}$ 表示第**b**个频率带的选择图.

### 1.3 空洞空间金字塔池化模块

为解决全局上下文信息整合的问题引入了空洞空间金字塔池化模块, 如图5所示, ASPP通过应用不同膨胀率的卷积操作, 有效地捕捉了不同尺度的地形特征, 同时通过全局平均池化获取了全局上下文信息, 通过将多尺度特征和全局信息进行融合, 提高了特征表示的丰富性和准确性.

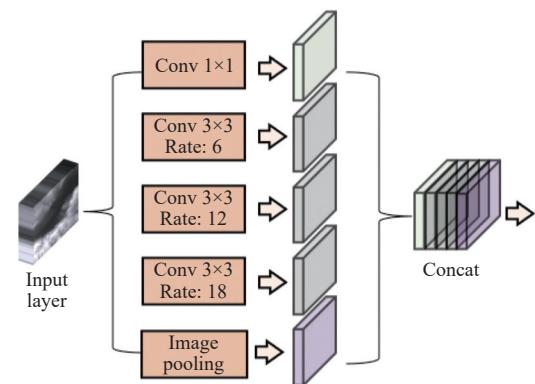


图5 ASPP结构

设输入特征图为 $G$ , 经过ASPP处理后的输出特征图为 $Y$ . ASPP中不同膨胀率的卷积操作可表示为:

$$Y_d = Conv_d(G) \quad (12)$$

其中,  $Conv_d$ 表示膨胀率为 $d$ 的卷积操作. 所有膨胀卷积操作及全局平均池化结果的拼接与融合得到最终的输出特征图 $Y$ , 本文采取了3个 $3 \times 3$ 的空洞卷积, 采样率为6、12和18, 如式(13)所示:

$$Y = Conv([Y_1 \cdot Y_{d_1} \cdot Y_{d_1} \cdot Y_{gap}]) \quad (13)$$

其中,  $[ \cdot ]$ 表示特征图的拼接操作.

### 1.4 损失函数

超分辨率重建图像任务中, 一般将 $L_1$ 范数或者 $L_2$ 范数作为损失函数, 但根据Zhao等人<sup>[23]</sup>的实验结论所得, 在峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性指数(structural similarity index, SSIM)

方面,  $L_1$  范数作为损失函数效果更好, 故模型采用  $L_1$  范数作为损失函数, 如式 (14) 所示:

$$L_1 = \frac{1}{n} \sum_{i=1}^n |y_i - F(x_i)| \quad (14)$$

其中,  $y_i$  是目标值,  $F(x_i)$  是估计值,  $n$  是训练样本的数量.

## 2 实验与结果分析

本实验所使用平台是国家超级计算西安中心, 基于 Python 语言和 PyTorch 1.8.0 深度学习框架下训练 DRFA-SR.

### 2.1 数据集与评价指标

本实验使用陕西秦岭 DEM 作为实验对象, 秦岭山脉地形的起伏变化和高度差使得其具有多样的地形和复杂的地貌特征, 可以充分训练和验证本文模型.

由于 DEM 数据稀少, 不足以满足神经网络训练, 因此本文使用公开数据集 DIV2K 来用作预训练, 并通过迁移学习, 将训练好的模型进行微调 (fine-tune) 更好地适应 DEM 超分辨率重建任务, 提高性能表现. 该 DEM 精度为 30 m, 大小为  $8643 \times 5407$ . 将该数据进行裁剪, 分为 700 块大小为  $256 \times 256$  的块, 将产生的数据集按照 7:2:1 的比例分为训练集  $D_1$ , 验证集  $D_2$  和测试集  $D_3$ , 通过降采样将训练集与验证集中的高分辨率版本得到低分辨率版本, 然后通过 Prewitt 算子得到低分辨率梯度图.

实验评价指标采用峰值信噪比和相对误差率 (absolute relative error, ARE) 来验证模型的有效性. PSNR 计算重建图像与原始图像之间的均方误差, 并将其转化为以 dB 为单位的指标, 数值越高表示重建图像质量越好, 如式 (15) 所示:

$$PSNR = 10 \lg \frac{D^2 \times MN}{\sum_{x=1}^M \sum_{y=1}^N (I(x,y) - I_w(x,y))^2} \quad (15)$$

ARE 是预测值和真实值之间的相对差异, 将其绝对值化并除以真实值的指标. 其值表示了预测值与真实值之间的误差相对于真实值的大小. ARE 的值越小, 表示预测值和真实值之间的误差越小, 即模型的预测越准确. 相反, 表示预测值和真实值之间的误差越大, 模型的预测准确性越低, 计算公式如下:

$$ARE = \frac{1}{M \times N} \sum_{x=1}^M \sum_{y=1}^N \left| \frac{I_w(x,y) - I(x,y)}{I(x,y)} \right| \quad (16)$$

式 (15) 和式 (16) 中,  $I(x,y)$  代表的是原 DEM 的像

素值,  $I_w(x,y)$  代表的重建后 DEM 中各像素的值,  $M \times N$  是图像的尺寸大小,  $D$  是信号的峰值即是图像中最大像素值. 并针对 DEM 地理细节, 额外引入坡度  $E_{Slope}$  和坡向  $E_{Aspect}$  作为评估指标.

### 2.2 实验设置

训练过程中采用 Adam 优化器, 设定  $\beta_1=0.9$ ,  $\beta_2=0.999$ ,  $\epsilon=2 \times 0.0001$ , 每 300 个 epoch 学习率衰减一半, 在 1500 次得到最佳模型, 实验使用 DCU 进行训练.

### 2.3 定量评价

为了充分验证 DRFA-SR 的先进性, 本节将同一地区不同分辨率的 DEM 进行对比分析, 表 1 和表 2 列出了 6 种模型分别在两种不同精度下进行 2 倍和 3 倍超分辨率重建后 PSNR 和 ARE 对比结果. 由测试数据集上的评价结果可以看出, 所提 DRFA-SR 在数据集上均实现了更好的 PSNR 和 ARE 结果, 证明其性能优越.

表 1 不同模型重建 DEM 指标

DEM 精度 (m)	缩放 因子	DEM 重建 方法	PSNR (dB)	ARE	$E_{Slope}$	$E_{Aspect}$
2	12.5	Bicubic <sup>[24]</sup>	31.89	0.794	0.903	4.483
		EDSR <sup>[25]</sup>	34.16	0.572	0.774	4.597
		ESRGAN <sup>[20]</sup>	34.23	0.569	0.772	4.596
		RCAN <sup>[26]</sup>	34.27	0.573	0.773	4.599
		SwinIR <sup>[27]</sup>	34.61	0.554	0.742	4.679
		DRFA-SR	34.58	0.552	0.741	4.691
3	30	Bicubic	27.13	1.766	1.244	5.327
		EDSR	30.49	1.399	1.069	5.296
		ESRGAN	30.47	1.396	1.068	5.304
		RCAN	30.52	1.401	1.063	5.293
		SwinIR	30.72	1.298	1.058	5.186
		DRFA-SR	30.79	1.362	1.057	5.183
2	30	Bicubic	28.33	1.766	1.537	11.207
		EDSR	31.52	0.899	1.317	11.392
		ESRGAN	31.43	0.896	1.311	11.390
		RCAN	31.69	0.901	1.316	11.367
		SwinIR	32.79	0.832	1.260	11.717
		DRFA-SR	32.72	0.819	1.259	11.703
3	30	Bicubic	23.07	3.821	2.115	13.217
		EDSR	27.80	2.477	1.817	13.245
		ESRGAN	27.85	2.472	1.814	13.261
		RCAN	27.87	2.498	1.805	13.236
		SwinIR	29.02	2.378	1.899	13.165
		DRFA-SR	28.13	2.378	1.799	13.162

表 2 HIFEB 和 ASPP 有效性验证结果

对照项	FreqSelect	ASPP	PSNR (dB)	ARE
1	—	—	31.67	0.886
2	√	—	32.21	0.843
3	—	√	32.41	0.844
DRFA-SR	√	√	33.93	0.824

具体而言, DRFA-SR 与基于 Transformer 的 SwinIR 相比, 在缩放因子为 2 时,  $E_{Slope}$  和  $E_{Aspect}$  两者效果相当, 但随着缩放因子上升, DRFA-SR 在  $E_{Slope}$  和  $E_{Aspect}$  上更具有优势, ARE 在任意缩放因子下均优于 SwinIR, 说明 DRFA-SR 在纹理细节更加丰富, 更加重建出接近于原始图像高低频细节. 而与其他 DEM 超分辨率模型相比, DRFA-SR 在 4 个客观评价中均取得了优势. 同时对比结果还显示出, 对于同种模型在不同精度下重建结果也具有较大差异, 例如 DRFA-SR 在精度分别为 30 m, 随着缩放因子变大 PSNR 下降幅度比在 12.5 m 大. 并且随着缩放因子的增加, 所有方法的  $E_{Slope}$  和  $E_{Aspect}$  值都上升, 这表明随着 DEM 缩放因子增加, DEM 重建模型性能相对降低, 出现一定的重建误差. 在 12.5 m

精度下, 所有模型重建效果也随着缩放因子的增加而降低, 说明在更高精度要求下, 会导致较高的重建误差, 重建模型面临更大的挑战. 因此在实际应用中, 应该根据具体情况, 选择合适的缩放因子以平衡精度要求和模型性能.

从图 6(h) 可以得出, DRFA-SR 提取结果在平坦区域空间分布上明显好于其他方法, 而在陡峭区域 DRFA-SR 能够重建出更精确的纹理效果. 在坡向变化复杂的地区, DRFA-SR 能够细致恢复出接近原始数据的 DEM.

图 7 是重建后 DEM 的坡度图, 随着坡度降低, 6 种方法提取到的坡度数据精度均得到提升, 且与实际结果逐渐接近, 其中 DRFA-SR 在 6 种方法中重建效果最好.

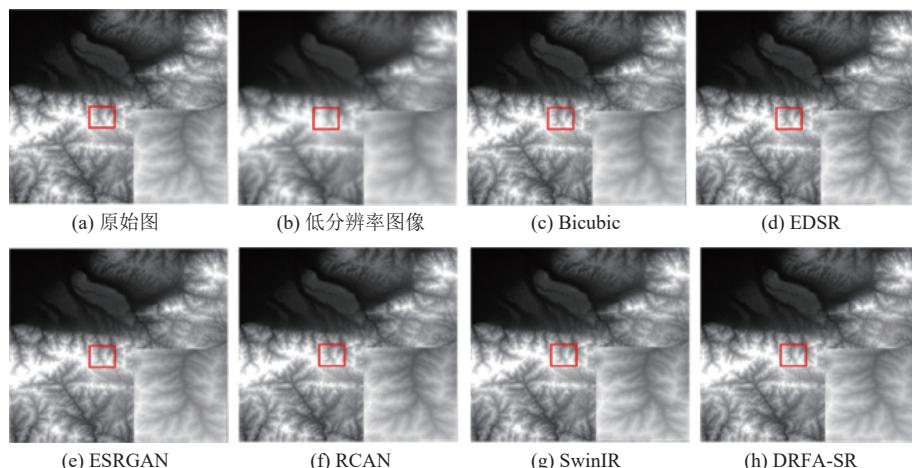


图 6 分辨率模型重建结果对比 (DEM 精度: 30 m; 缩放因子: 3)

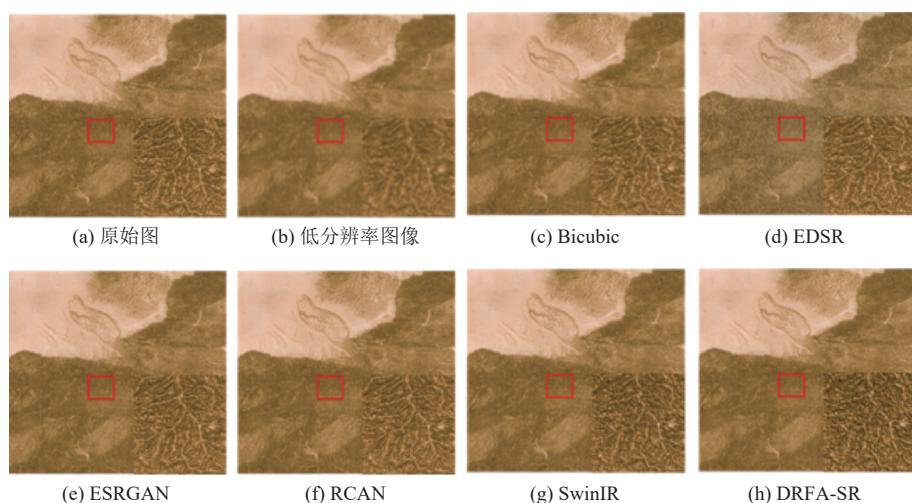


图 7 不同超分辨率模型坡度重建结果对比 (DEM 精度: 30 m; 缩放因子: 3)

## 2.4 消融实验

### 2.4.1 HIFEB 和 ASPP 有效性验证

DRFA-SR 主要由 HIFEB 和 ASPP 组成, 其中 HIFEB 含有 FreqSelect 模块, 为了验证 FreqSelect 模块和 ASPP 对 DEM 高低频特征提取以及重建 DEM 提升的提升效果, 进行了 4 组对比实验, 结果如表 2 所示。

通过对比实验表明, 在数字高程模型超分辨率重建中, FreqSelect 和 ASPP 模块的加入均显著提升了模型的重建效果: 基础模型的  $PSNR$  为 31.67 dB,  $ARE$  为 0.886, 表现较差。引入 FreqSelect 模块后,  $PSNR$  提高到 32.21 dB,  $ARE$  降低至 0.843, 表明该模块通过有效提取高低频特征, 增强了模型的特征表示能力。引入 ASPP 模块后,  $PSNR$  提升至 32.41 dB,  $ARE$  降低至 0.844, 说明 ASPP 通过多尺度特征提取和扩展感受野, 显著改善了重建质量。最终, 结合了 FreqSelect 和 ASPP 模块的 DRFA-SR 模型取得了最佳性能,  $PSNR$  达到 33.93 dB,  $ARE$  降至 0.824。这验证了两模块在高低频特征提取和多尺度特征融合方面的协同增效作用, 显著提升了 DEM 超分辨率重建的整体效果。

## 3 结束语

本文提出一种基于深度残差频率自适应网络模型 DRFA-SR, 通过使用高低频特征提取残差模块和空洞空间金字塔池化模块, 更充分利用特征图中的信息。并在 HIFEB 中使用了 FreqSelect 模块, 根据频率选择出重要的特征信息, 真实地重建出 DEM 的地理特征。

此外, 在梯度域和高度域双重约束下进行重建, 提升模型的超分辨率重建能力。实验结果表明, DRFA-SR 通过提取高低频特征和整合多尺度信息取得了显著的模型性能, 与 EDSR 和 SwinIR 等最新算法相比, 所提 DRFA-SR 在各个指标中均取得最优效果。

## 参考文献

- 1 Xiong LY, Tang G, Yang X, et al. Geomorphology-oriented digital terrain analysis: Progress and perspectives. *Journal of Geographical Sciences*, 2021, 31(3): 456–476. [doi: [10.1007/s11442-021-1853-9](https://doi.org/10.1007/s11442-021-1853-9)]
- 2 Borzi G, Roig A, Tanjal C, et al. Flood hazard assessment in large plain basins with a scarce slope in the Pampean Plain, Argentina. *Environmental Monitoring and Assessment*, 2021, 193(4): 177. [doi: [10.1007/s10661-021-08988-1](https://doi.org/10.1007/s10661-021-08988-1)]
- 3 Wang HX, Cheng YM, Liu N, et al. An illumination-invariant shadow-based scene matching navigation approach in low-altitude flight. *Remote Sensing*, 2022, 14(16): 3869. [doi: [10.3390/rs14163869](https://doi.org/10.3390/rs14163869)]
- 4 An R, Lee JA. CAMDLES: CFD-DEM simulation of microbial communities in spaceflight and artificial microgravity. *Life*, 2022, 12(5): 660. [doi: [10.3390/life12050660](https://doi.org/10.3390/life12050660)]
- 5 Li ZX, Zhu XH, Yao SL, et al. A large scale digital elevation model super-resolution Transformer. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 124: 103496. [doi: [10.1016/j.jag.2023.103496](https://doi.org/10.1016/j.jag.2023.103496)]
- 6 Yao S, Cheng YM, Yang F, et al. A continuous digital elevation representation model for DEM super-resolution. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2024, 208: 1–13. [doi: [10.1016/j.isprsjprs.2024.01.001](https://doi.org/10.1016/j.isprsjprs.2024.01.001)]
- 7 Wang H, Xiong LY, Hu GH, et al. DEM super-resolution framework based on deep learning: Decomposing terrain trends and residuals. *International Journal of Digital Earth*, 2024, 17(1): 2356121. [doi: [10.1080/17538947.2024.2356121](https://doi.org/10.1080/17538947.2024.2356121)]
- 8 Lin R, Mei G, Xu N. Accurate and automatic mapping of complex debris-covered glacier from remote sensing imagery using deep convolutional networks. *Geological Journal*, 2023 (published online). [doi: [10.1002/gj.4615](https://doi.org/10.1002/gj.4615)]
- 9 Demiray BZ, Sit M, Demir I. D-SRGAN: DEM super-resolution with generative adversarial networks. *SN Computer Science*, 2021, 2(1): 48. [doi: [10.1007/s42979-020-00442-2](https://doi.org/10.1007/s42979-020-00442-2)]
- 10 Vasile I, Tudor E, Sburlan IC, et al. Experimental validation of LiDAR sensors used in vehicular applications by using a mobile platform for distance and speed measurements. *Sensors*, 2021, 21(23): 8147. [doi: [10.3390/s21238147](https://doi.org/10.3390/s21238147)]
- 11 Lenda G, Borowiec N, Marmol U. Study of the precise determination of pipeline geometries using UAV scanning compared to terrestrial scanning, aerial scanning and UAV photogrammetry. *Sensors*, 2023, 23(19): 8257. [doi: [10.3390/s23198257](https://doi.org/10.3390/s23198257)]
- 12 Arroyo-Mora J P, Kalacska M, Roghani A, et al. Assessment of UAS photogrammetry and planet imagery for monitoring water levels around railway tracks. *Drones*, 2023, 7(9): 553. [doi: [10.3390/drones7090553](https://doi.org/10.3390/drones7090553)]
- 13 Bagheri H, Schmitt M, Zhu XX. Fusion of multi-sensor-derived heights and OSM-derived building footprints for urban 3D reconstruction. *ISPRS International Journal of Geo-information*, 2019, 8(4): 193. [doi: [10.3390/ijgi8040193](https://doi.org/10.3390/ijgi8040193)]
- 14 Shen HF, Meng XC, Zhang LP. An integrated framework for the spatio-temporal-spectral fusion of remote sensing images.

- IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(12): 7135–7148. [doi: [10.1109/TGRS.2016.2596290](https://doi.org/10.1109/TGRS.2016.2596290)]
- 15 Kováčová G, Rudloff B. Convex projection and convex multi-objective optimization. Journal of Global Optimization, 2022, 83(2): 301–327. [doi: [10.1007/s10898-021-01111-1](https://doi.org/10.1007/s10898-021-01111-1)]
- 16 Zhang X, Liu Q, Li XM, et al. Non-local feature back-projection for image super-resolution. IET Image Processing, 2016, 10(5): 398–408. [doi: [10.1049/iet-ipr.2015.0467](https://doi.org/10.1049/iet-ipr.2015.0467)]
- 17 He Y, Yap KH, Chen L, et al. A soft MAP framework for blind super-resolution image reconstruction. Image and Vision Computing, 2009, 27(4): 364–373. [doi: [10.1016/j.imavis.2008.05.010](https://doi.org/10.1016/j.imavis.2008.05.010)]
- 18 Chen ZX, Wang XW, Xu ZK, et al. Convolutional neural network based DEM super resolution. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Prague: ISPRS, 2016. 247–250.
- 19 Xu ZK, Chen ZX, Yi WW, et al. Deep gradient prior network for DEM super-resolution: Transfer learning from image to DEM. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 150: 80–90. [doi: [10.1016/j.isprsjprs.2019.02.008](https://doi.org/10.1016/j.isprsjprs.2019.02.008)]
- 20 Jiao DL, Wang DJ, Lv HY, et al. Super-resolution reconstruction of a digital elevation model based on a deep residual network. Open Geosciences, 2020, 12(1): 1369–1382. [doi: [10.1515/geo-2020-0207](https://doi.org/10.1515/geo-2020-0207)]
- 21 Lin X, Zhang QQ, Wang HY, et al. A DEM super-resolution reconstruction network combining internal and external learning. Remote Sensing, 2022, 14(9): 2181. [doi: [10.3390/rs14092181](https://doi.org/10.3390/rs14092181)]
- 22 Zhou AN, Chen YM, Wilson JP, et al. A multi-terrain feature-based deep convolutional neural network for constructing super-resolution DEMs. International Journal of Applied Earth Observation and Geoinformation, 2023, 120: 103338. [doi: [10.1016/j.jag.2023.103338](https://doi.org/10.1016/j.jag.2023.103338)]
- 23 Zhao H, Gallo O, Frosio I, et al. Loss functions for image restoration with neural networks. IEEE Transactions on Computational Imaging, 2017, 3(1): 47–57. [doi: [10.1109/TCI.2016.2644865](https://doi.org/10.1109/TCI.2016.2644865)]
- 24 Keys R. Cubic convolution interpolation for digital Image processing. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1981, 29(6): 1153–1160. [doi: [10.1109/TASSP.1981.1163711](https://doi.org/10.1109/TASSP.1981.1163711)]
- 25 Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Honolulu: IEEE, 2017. 136–144.
- 26 Zhang YL, Li KP, Li K, et al. Image super-resolution using very deep residual channel attention networks. Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich: Springer, 2018. 286–301.
- 27 Liang J, Cao J, Sun GL, et al. SwinIR: Image restoration using Swin Transformer. Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Montreal: IEEE, 2021. 1833–1844.

(校对责编: 孙君艳)