

基于多尺度残差增强网络的 DEM 超分辨率重建

韩超, 张晓滨*

(西安工程大学 计算机科学学院, 陕西 西安 710699)

摘要:数字高程模型(DEM)被认为是最重要的基础地理数据模型之一,在水文分析、路径规划和建模等方面有着广泛的应用。然而,通过具有更高精度的传感器获取大面积高分辨率 DEM 数据的高成本对许多地理分析应用提出了挑战。结合多尺度特征、残差学习和多尺度通道注意力机制,该文提出了基于多尺度残差多通道注意力增强网络的数字高程模型超分辨率重建方法,其中多尺度残差多通道注意力增强模块(MRCAEM)利用具有多个不同的卷积核大小的卷积层组合,经过多尺度通道注意力机制可更好地捕捉不同尺度的语义信息,细化多尺度特征的提取。经特征融合后,通过重建模块可重建出更真实的高分辨率 DEM。实验证明,该方法的均方根误差(RMSE)对比其他方法降低了约2%~30%。

关键词:数字高程模型;超分辨率重建;多尺度;残差融合网络;多尺度通道注意力;可变形卷积

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2025)03-0009-09

doi:10.20165/j.cnki.ISSN1673-629X.2024.0319

DEM Super-resolution Reconstruction Based on Multi-scale Residual Enhancement Network

HAN Chao, ZHANG Xiao-bin*

(School of Computer Science, Xi'an Polytechnic University, Xi'an 710699, China)

Abstract: Digital Elevation Models (DEMs) are considered one of the most important foundational geographic data models, with widespread applications in hydrological analysis, path planning, and modeling. However, the high cost of acquiring large-area, high-resolution DEM data with more precise sensors poses a challenge for many geographic analysis applications. Combining multi-scale features, residual learning, and multi-scale channel attention mechanisms, we propose a digital elevation model super-resolution reconstruction method based on a Multi-Scale Residual Multi-Channel Attention Enhancement Network. The Multi-Scale Residual Multi-Channel Attention Enhancement Module (MRCAEM) utilizes a combination of convolutional layers with multiple different kernel sizes, and through the multi-scale channel attention mechanism, it better captures semantic information at different scales, refines multi-scale feature extraction, and reconstructs more realistic high-resolution DEMs through feature fusion and reconstruction modules. Experimental results show that the proposed method reduces the Root Mean Square Error (RMSE) by approximately 2%~30% compared to other methods.

Key words: digital elevation model; super-resolution reconstruction; multi-scale; residual fusion network; multi-scale channel attention; deformable convolution

0 引言

数字高程模型(DEM)是地形的重要数字表示形式之一,它以规则的栅格形式存储和表达空间高程信息。这些模型已用于测绘遥感、农林规划、土木工程和地学分析等领域^[1]。受限于地形测绘的制造工艺和成本,DEM的精度和测量范围很难通过测量手段在短期内得到提高^[2]。因此,探究如何能够高效地获取高精度 DEM 数据对于 DEM 的广泛应用具有重要意义^[3]。

高分辨率的 DEM 包含更多的信息,能够更好地反映实际地表,这对于正确推导坡度、坡向和地形湿度指数等地形因子起着至关重要的作用^[4]。数字高程模型超分辨率重建(DEM SR)旨在通过基于已知位置估计未知高程值来改进低分辨率 DEM^[5]。在不需要更新测量设备的情况下,通过数据处理提高 DEM 数据的分辨率。基于深度学习的方法具有大量的参数,可以在训练过程中捕捉地形分布规律,在 DEM SR 任务

收稿日期:2024-07-02

修回日期:2024-11-06

基金项目:陕西省自然科学基金基础研究计划项目(2023-JC-YB-568)

作者简介:韩超(2000-),男,硕士研究生,研究方向为图像处理;通信作者:张晓滨(1970-),男,副教授,硕导,硕士,研究方向为数据挖掘和个性化服务技术与应用。

中具有更大的潜力^[6]。与传统方法相比,这种解决方案的主要优点是低成本和高效^[7]。

DEM SR 现有的 SR 方法可以分为三类:基于传统插值方法的 SR、基于重建方法的 SR^[8]和基于深度学习的 SR。插值使用连续的曲面来拟合地形表面,包括反距离、克里格、双线性和双三次插值^[9]。该方法的性能在不同的地形条件下会有所不同,内插 DEM 的地形特征将被过度平滑并且精度不稳定。重建方法依赖于数据融合,并使用多源 DEM 的互补信息来生成 HR DEM^[10]。基于深度学习的方法可以通过学习原始 DEM 的一些重复和相似的模式,并将高频信息引入到低分辨率 DEM 的超分辨率版本中,从而提高超分辨率效果^[11]。将 CNN 方法用于 DEM SR 可以被视为图像 SR 的扩展。Chen 等人^[12]在第一个此类应用中使用 SRCNN 来 DEM SR 并取得较好的效果。DEMIRAY B Z 等人首先提出 D-SRGAN^[13]作为第一个基于 GAN 的 DEM SR 模型。Deng 等人提出 D-SR-CAGAN^[14],它在 D-SRGAN 的基础上增加了通道注意模块,取得了比 D-SRGAN 更令人满意的结果。Zhang 和 Yu^[6]还验证了具有 ResNet 结构的深度网络可以实现更好的 DEM SR 性能。Lin 等人^[15]将内部学习的 ZSSR 方法引入到 DEM SR 中。He 等人^[16]引入了傅里叶变换作为编码器,并获得了良好的性能,这可以丰富现有的 DEM SR 任务编码器。此外,Zhang 等人^[17]考虑到 DEM 特征的特点,引入了变形卷积(Dconv)^[18]模块,增强了捕获不规则 DEM 特征(TfaSR)的能力。Zhou 等人^[19]提出了一种结合地形特征的 MTF-SR 方法,在输出 HR DEM 之前集成了矢量地形特征,显著提高了模型的精度。Jiang 等人^[20]

使用高山数据作为研究数据,并在 ResNet 中构建了一个新的损失函数,该函数结合了坡度和曲率等地形参数。Yao 等人^[21]采用了 DEM SR 的隐式神经表示模型(EBCF-CDEM)。

虽然现有的图像 SR 方法比传统的空间插值方法有更好的性能,但它们仍不足以处理地形特征恢复,且网络层数的增加意味着更大的计算量和更多的时间消耗^[22]。另外,由于图像退化和内容多样性等因素的复杂性,DEM 多尺度信息提取是 DEM SR 的关键细节信息。除了已使用的 CNN 和 GANS 模型外,新的思想是在网络结构中使用残差通道注意块(RCAB)^[23]以增强特征细节捕捉。RCAB 在随机共振重建中得到补充,在区分生成特征方面具有优势,并且可以集成到端到端的深度网络中进行训练。

针对 DEM SR 中存在的上述问题,DEM 具有多尺度空间特征、空间异质性特征和不同地形特征,SR 模型的直接转换可能无法充分考虑这些特征。文中模型是从 DEM 多尺度信息提取和特征细节捕捉优化的角度来设计的,提出了一种基于多尺度残差多通道注意力增强网络用于 DEM 图像重建。该方法集成了多尺度残差多通道注意力增强模块(MRCAEM),可变卷积和亚像素卷积三个模块,可以提取足够的 DEM 特征,最终生成高质量的 DEM。

1 基于多尺度残差多通道注意力增强网络

1.1 网络结构

该文提出一种基于多尺度残差多通道注意力的 DEM 超分辨率重建模型,对地形特征进行了提取和优化,框架如图 1 所示。

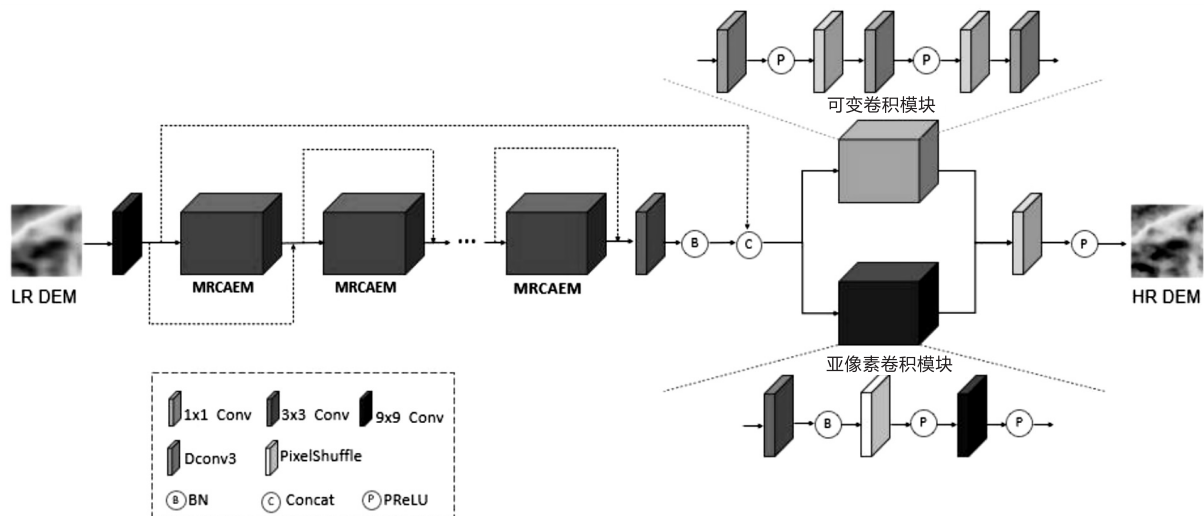


图 1 基于多尺度残差多通道注意力增强网络的 DEM 超分辨率模型

该模型设计了一个多尺度残差通道注意力增强网络,旨在模拟更真实的地理分布格局。模型的设计考虑了多尺度残差多通道注意力增强模块(MRCAEM),

使用 9×9 卷积添加到输入,由多个 MRCAEM 模块用于特征提取。亚像素卷积模块和可变卷积模块用于尺寸放大。除此之外,使用常连接输入和输出,以确保网

络的稳定性。

1.2 多尺度残差多通道注意力增强模块 (MRCAEM)

DEM 图像中包含丰富的细节信息,这些信息可能在不同尺度上表现出来。传统的卷积网络可能只能关注到某一个尺度的信息,因此可能无法捕捉到所有重要的细节。为了解决这一问题,该文提出多尺度残差多通道注意力增强模块 (MRCAEM) 通过结合多尺度特征提取、MS-CAM^[24] 通道注意力机制和残差学习策略来增强特征融合能力,并利用多尺度信息更全面地捕捉 DEM 图像细节。

残差学习 ResNet^[25] 在图像 SR 重建的情况下, BN 层改变了初始源的值并且限制了结构适应性,影响最终重建结果。为了避免 BN 层的负面影响,该文通过去除 BN 层来修改原始的残差块。设计的残差块中由

两个大小不同的卷积核残差块组成,每个残差块由两个卷积核和 PReLU 激活函数组成,并且 BN 层都被删除,如图 2 (MRCAB-A, MRCAB-B, MRCAB-C) 所示。并使用不同的卷积核提取多尺度细节信息,而 MS-CAM 在 CAM 的基础上进行了改进,通过引入多尺度的信息,能够更好地捕捉图像中不同尺度的语义信息 (图 2 MS-CAM),后面的实验证明它可以用来聚合局部和全局上下文,并相对更好地融合不连续的细节信息,可以进一步改善最终的重建结果。然而,将 MS-CAM 注意力直接纳入核心网络将显著损害网络的提取特性,这不利于捕捉 DEM 图像纹理和细节。残差学习用于将 MS-CAM 注意力的输入和加权特征相加作为网络的输出。MS-CAM 通道注意力块被集成到残差块后,构成新的三个残差通道注意力块 (MRCAM-A, MRCAM-B, MRCAM-C),如图 2 所示。

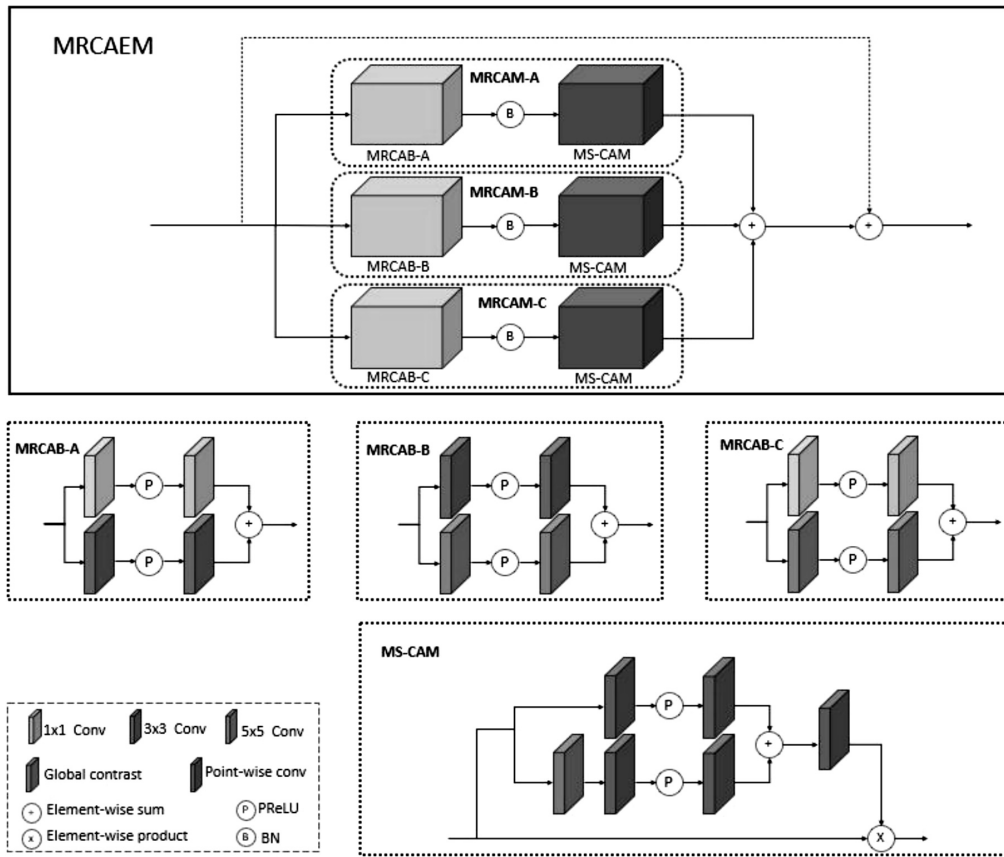


图 2 多尺度残差通道注意力增强模块 (MRCAEM)

该文提出的多尺度残差多通道注意力增强模块 (MRCAEM) 由三个残差通道注意力块 (MRCAM-A, MRCAM-B, MRCAM-C) 组成,具有各种尺度的卷积核,所使用的方法可以共享使用各种卷积核提取的特征数据以获得 DEM 图像多尺度信息,如图 2 所示。对于多尺度多残差通道注意力增强模块 (MRCAEM),使用了局部残差学习策略来提高重建性能,并使用通道注意力更好地捕捉 DEM 图像中不同尺度的语义信息。

在每个多尺度多残差通道注意力增强模块 (MRCAEM) 中的融合特征之后,特征通过残差连接被添加,然后被发送到下一个多尺度多残差通道注意力增强模块 (MRCAEM)。最后加入原始特征,实现不同 DEM 图像尺度特征的交互。

1.3 亚像素卷积模块

在深度残差模块之后,需要进行上采样操作来重建图像。反卷积、直接上采样和双线性插值法是最常

用的放大基于深度学习的随机共振重建的方法。亚像素卷积(又称像素混洗)是一种有效的图像特征映射扩展方法。

PixelShuffle(亚像素卷积神经网络)^[26]通过亚像素卷积和多通道重组从低分辨率特征图获得高分辨率特征图,如图 3 所示。PReLU 通过引入一个额外的参数,改进了 ReLU 激活函数的表达能力。PReLU 在许多应用中已经表现得很好,其有效地解决了过拟合问题而不增加计算复杂度。PReLU 可以提供更多的灵活性和自适应性,这种自适应性可以更好地捕捉复杂的图像细节。




图 3 亚像素卷积

该模块由两个卷积层、一个 PixelShuffle 层、一个 BN 层和两个 PReLU 层组成。重组过程是通过填充网格并根据相同的规则将其划分为每个低分辨率像素来完成的,使用 PixelShuffle 对 DEM 进行采样。因此,该文将亚像素卷积模块(见图 1)作为一种特征上采样方法。

1.4 可变形卷积模块

地形特征具有多样性和异构性,可能涉及多种尺寸和形态。为了解决这个问题,可变形卷积被认为是一种潜在的解决方案,因为它能够在模型实现中灵活而有效地处理各种地形特征的形状和尺寸变化^[27],如图 4 所示。




图 4 数字高程模型上的可变形卷积

可变形卷积可以有效处理复杂地形,提高模型对地形变化的鲁棒性,通过调整卷积核的位置和形状来更好地恢复 DEM 图像中的细节信息,减少地形特征信息丢失。

该文使用 DCNv3^[28],如图 5 所示。DCNv3 共享投影权重,借鉴了可分离卷积的思路,采用与位置无关的权重代替分组权重,在不同采样点之间共享投影权重,所有的采样位置依赖性都得以保留;引入多组机制,将空间聚合过程分成若干组,每个组都有独立的采样偏移量。自此,单个 DCNv3 层的不同组拥有不同的空间聚合模式,从而产生丰富的特征多样性;进行了采样点调制标量归一化。




图 5 可变形卷积 v3

因此,该文提出使用一个可变形卷积模块提取变形卷积 DEM 深度特征。该模块由七层组成,包括三个可变形卷积层、两个普通卷积层和两个 PReLU 层,以实现准确性和效率之间的权衡(图 1 可变卷积模块)。模块的输入就是之前多尺度残差多通道注意力增强模块(MRCAEM)提取的特征图,可以更好地利用这些深度特征在可变卷积模块之后,用于从最终的超分辨率 DEM 中恢复提取的地形特征。

1.5 DEM 超分辨率模型协同损失

损失函数直接决定了网络优化的方向,影响最终生成 DEM 的质量,该文从地形特征优化的角度计算协同损失。

在图像重建任务中,传统的方法主要关注图像的重建精度。然而,最近的研究表明,图像视觉质量可能与图像精度不一致,这意味着面向精度的方法可能输出缺乏高频细节的过度平滑的图像^[29]。

DEM SR 需要保证高程和 DEM 要素的精度。前者可以通过计算生成的 HR DEM 与真实 DEM 之间的损失来实现,后者需要利用特征提取器提取相应的特征,然后计算提取的特征之间的损失来实现。

因此,可以通过 RMSE 损失分别优化 HR DEM 和真实 DEM 之间的高程和特征,设计协同损失为高程精度损失和 DEM 要素损失的组合,二者组成协同损失函数 Loss,相关公式如下:

$$\text{RMSE}(y_i, \hat{y}_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

$$\text{Loss} = \text{RMSE}_g + \beta \text{RMSE}_d \quad (2)$$

其中, RMSE_g 为高程损失, RMSE_d 为 DEM 要素损失, 两者均可由式 1 计算; y_i 表示真实高程值, \hat{y}_i 表示预测高程值; n 表示计数的像素数; β 为权重系数。

2 实验

2.1 实验设置

文中使用的 DEM 数据来自 FEN 论文^[30], 如图 6 所示。DEM 分辨率为 30 m, 研究区域为 7 201 m × 7 201 m。考虑到实验设备和数据可用性的合理性, 需要对高分辨率 DEM 进行下采样处理, 以获取相应的低分辨率 DEM, 下采样因子设定为常见的 4 倍目标尺度。实验的设置是 1 : 1 的超分辨率, 所以将下采样的 DEM 恢复到其原始分辨率大小, 采用双线性插值方法完成尺寸恢复的过程。将原始 DEM 数据切割的 64 × 64 分辨率的 DEM, 总共得到 12 769 个 DEM 数据。训练集和测试集的比例为 8 : 2。

为了评估该方法, 将其与几种 DEM SR 方法进行了比较, 包括双三次插值 (Bicubic)^[31]、SRResNet^[29] 和 SRCNN^[32]、SRGAN^[29]、TfSR^[17]、EBCF-CDEM^[21]。




图6 研究区域及高程分布

为了全面比较不同 DEM SR 算法的性能, 增强实验结果的说服力, 实验在测试集中选择了四种类型的区域进行测试。

利用图 7 中的 DEM 高程分布信息可以直观地发现它们之间的差异: T1 和 T3 的整体高程 (约 1 180 ~ 1 651 m) 大致相似, 地形起伏较大, T2 整体高程平均约 1 400 m, T4 整体高程最小 (约 1 041 ~ 1 470 m)。这四种 DEM 在试验数据中具有典型性。实验在 PyTorch 框架部署 SR 重建网络, 并在 NVIDIA V100 16 GB 显卡上进行了训练。为了进行公平的比较, 所有模型使用 Adam 优化器进行 100 次模型训练, 学习率为 0.000 1, 批量大小为 4, 损失权重设为 $\beta = 0.01$ 。

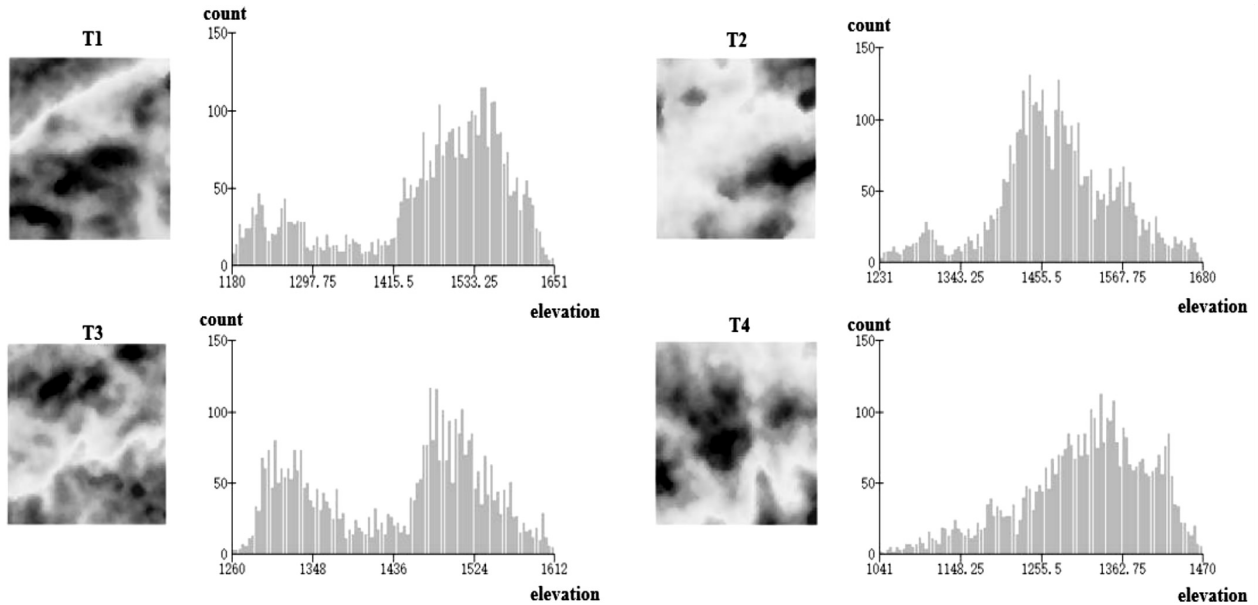


图7 四个测试区域及高程分布

2.2 质量评估方法

DEM 超分辨率模型的质量评估是验证其有效性的重要步骤, 考虑到地形在实际应用中的需求, 实验评估地形质量的高程精度和 DEM 图像的结构信息。高程精度方面, 采用了 RMSE (均方根误差) 和 MAE (平均绝对误差) 指标。RMSE 对于高程值较大的地形位置误差非常敏感, 能够反映局部地形特征的保持情况; 而 MAE 则更能反映全局高程误差。在 DEM 图像的结构信息评估中, 采用了 SSIM (结构相似性指数), SSIM 的值为范围在 [0, 1]。当 SSIM 接近 1 时, SR 图像更接近

于真实的 HR 样本。

该文基于 RMSE、MAE 和 SSIM 这三个指标对 DEM 超分辨率效果进行了评价。

$$\text{RMSE}(y_i, \hat{y}_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

$$\text{SSIM} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_x\sigma_y + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (5)$$

$$C_1 = (K_1L)^2 \quad (6)$$

$$C_2 = (K_2L)^2 \tag{7}$$

公式 3 和公式 4 中, y_i 表示真实高程值, \hat{y}_i 表示预测高程值, n 表示计数的像素数。公式 5^[33] 中, x 和 y 分别表示两张 DEM 图像, μ_x 和 μ_y 分别为 x 和 y 的平均值; μ_x^2 和 μ_y^2 分别为 x 和 y 的标准差; C_1 和 C_2 是用于保持公式 6 和公式 7^[33] 稳定性的固定参数, 默认 $K_1 = 0.01$, $K_2 = 0.03$, 其中 L 是像素的最大值 ($L = 255$)。

2.3 实验结果分析

实验将双三次插值 (Bicubic)^[31]、SRResNet^[29] 和

SRCNN^[32]、SRGAN^[29]、TfaSR^[17]、EBCF-CDEM^[21] 与文中方法在不同的测试区域进行比较, 结果如表 1 所示。从表 1 中可以看出: 在 T1、T2、T3 和 T4 测试区, 文中方法在高程精度 RMSE、MAE 和结构信息 SSIM 方面优于对比方法。

上述结果表明文中方法在复杂的区域 DEM SR 任务中具有良好的效果。

表 1 不同方法的准确度

区域	方法	RMSE	MAE	SSIM
T1	Bicubic	11.348	8.852	0.909
	SRResNet	9.252	5.983	0.876
	SRCNN	8.890	5.680	0.851
	SRGAN	60.390	57.849	0.841
	TfaSR	10.673	7.459	0.902
	EBCF-CDEM	10.681	7.778	0.923
	Ours	7.275	5.687	0.971
T2	Bicubic	11.457	8.467	0.907
	SRResNet	9.278	5.475	0.878
	SRCNN	9.044	5.367	0.869
	SRGAN	49.880	45.461	0.827
	TfaSR	11.039	7.692	0.874
	EBCF-CDEM	9.905	7.381	0.913
	Ours	7.176	5.327	0.972
T3	Bicubic	9.551	7.665	0.863
	SRResNet	9.265	6.077	0.811
	SRCNN	8.427	5.687	0.794
	SRGAN	12.220	11.338	0.822
	TfaSR	8.453	6.402	0.852
	EBCF-CDEM	9.055	6.766	0.888
	Ours	8.407	5.580	0.955
T4	Bicubic	10.319	8.158	0.910
	SRResNet	6.745	5.871	0.881
	SRCNN	8.101	5.627	0.872
	SRGAN	6.480	5.296	0.884
	TfaSR	9.099	6.836	0.913
	EBCF-CDEM	9.165	6.899	0.934
	Ours	6.375	5.072	0.973

2.4 目视评估

从目视评估的角度来看, 文中方法优于其他需要视觉评价的方法, 因为在许多情况下, 定量指标较好的图像视觉感知较差。

图 8 显示双三次插值 (Bicubic)^[31]、SRResNet^[29] 和 SRCNN^[32]、SRGAN^[29]、TfaSR^[17]、EBCF-CDEM^[21] 以及文中方法生成的高分辨率 DEM 结果。

然而, 这些结果之间存在许多差异。对于四个测

试区域(图8),SRCNN和SRResNet的结果显示过度平滑,甚至比传统的双三次插值法更差。

尽管SRGAN在图像视觉感知方面优于SRResNet,SRGAN在DEM数据上呈现出比SRResNet

更差的视觉效果。

对于四个测试区域,文中方法得到的结果与原始DEM的地形趋势更加一致,可以说明设计的超分辨率网络较其他方法更好地保留了测试区域内的地形细节。




图8 四个测试区域中不同方法的DEM SR结果

2.5 消融实验

为了进一步验证不同模块的作用,下面讨论不同模块的作用和优化操作包括多尺度残差多通道注意力增强模块(记为MRCAEM)特征提取过程中的特征融合方法(包括Concat和Add)、可变形卷积模块和亚像素卷积模块。

表2显示了在单独移除特定模块后的模型高程

表2 不同方法的消融实验高程精度

不同模块和优化操作				RMSE	MAE
1	MRCAEM(Concat)	可变形卷积	亚像素卷积	6.389	5.083
2	MRCAEM(Add)	可变形卷积	亚像素卷积	6.375	5.072
3	MRCAEM(Add)		亚像素卷积	11.932	9.196
4	MRCAEM(Add)	可变形卷积		6.465	5.102
5		可变形卷积	亚像素卷积	10.342	8.071

表3显示了研究不同数目的MRCAEM对网络的影响。

通过对表3的分析发现,当MRCAEM的数量从10增加到16时,网络的性能随后得到增强。然而,当

精度。

通过对表2的分析发现:(1)网络在高程精度和DEM特征方面表现最好,这说明所涉及的模块是必要的;(2)不同的模块对网络的贡献不同。MRCAEM模块和可变卷积模块是最重要的两个模块,其余三个模块也有类似的贡献。

MRCAEM的数目增加到18时,网络性能开始显示出随着网络的加深而下降的趋势。这是由于多个MRCAEM的积累导致特征冗余。因此,建议的网络采用16个MRCAEM从DEM图像中提取多尺度特征。

表 3 不同数量 MRCAEM 重建性能比较

模型	RMSE	MAE
MRCAEM-10	6.513	5.223
MRCAEM-12	6.458	5.165
MRCAEM-14	6.409	5.110
MRCAEM-16	6.375	5.072
MRCAEM-18	6.584	5.163

3 结束语

该文提出了一种新的基于多尺度残差多通道注意力增强网络用于 DEM 图像超分辨率重建,该方法集成了多尺度残差多通道注意力,可变卷积和亚像素卷积。多尺度残差多通道注意力增强模块可实现局部和全局空间特征的有效融合,提高多尺度特征信息的利用率;可变卷积模块可识别和提取多样性和异构性的地形特征;亚像素卷积模块实现特征上采样。实验结果表明,该方法可以获得比现有的基于经典插值和深度学习的 DEM SR 方法更好的结果。

多尺度信息的使用虽然可以充分利用邻域信息,但计算量增加,计算效率降低。未来的工作将重点放在训练地形特征到网络中,以约束超分辨率结果,使 SR DEM 能够保留更多的地形特征。笔者还计划使用更高分辨率的 DEM 和开放访问的低分辨率 DEM 来生成训练数据,而不仅仅是对高分辨率 DEM 进行下采样来获得训练数据。

参考文献:

- [1] 焦明东,李云昊,彭健,等. 机载激光雷达在大比例尺 DEM 生产中的应用[J]. 北京测绘,2021,35(12):1541-1544.
- [2] 张瑞辰,秦婉亭. 基于鲁棒亚像素卷积神经网络的 DEM 超分辨率重建[J]. 智能安全,2023,2(4):1-13.
- [3] 王大江. 基于深度学习的 DEM 影像超分辨率重建技术研究[D]. 南京:南京邮电大学,2022.
- [4] SCHUMANN G J P, BATES P D. The need for a high-accuracy, open-access global DEM[J]. *Frontiers in Earth Science*, 2018,6:225.
- [5] HABIB M. Evaluation of DEM interpolation techniques for characterizing terrain roughness [J]. *Catena*, 2021, 198: 105072.
- [6] ZHANG Y, YU W. Comparison of DEM super-resolution methods based on interpolation and neural networks[J]. *Sensors*,2022,22(3):745.
- [7] ZHU D, CHENG X, ZHANG F, et al. Spatial interpolation using conditional generative adversarial neural networks[J]. *International Journal of Geographical Information Science*,2020,34(4):735-758.
- [8] ORIANI F, MCCABE M F, MARIETHOZ G. Downscaling multispectral satellite images without colocated high-resolution data: a stochastic approach based on training images [J]. *IEEE Transactions on Geoscience and Remote Sensing*,2020,59(4):3209-3225.
- [9] REUTER H I, NELSON A, JARVIS A. An evaluation of void-filling interpolation methods for SRTM data [J]. *International Journal of Geographical Information Science*, 2007, 21(9): 983-1008.
- [10] LI X, SHEN H, FENG R, et al. DEM generation from contours and a low-resolution DEM [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*,2017,134:135-147.
- [11] 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.
- [12] CHEN Z, WANG X, XU Z, et al. Convolutional neural network based dem super resolution [J]. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*,2016,41(B3):247-250.
- [13] DEMIRAY B Z, SIT M, DEMIR I. D-SRGAN: DEM super-resolution with generative adversarial networks [J]. *SN Computer Science*,2021,2:1-11.
- [14] DENG X, HUA W, LIU X, et al. D-SRCAGAN: DEM super-resolution generative adversarial network [J]. *IEEE Geoscience and Remote Sensing Letters*,2022,19:1.
- [15] LIN X, ZHANG Q, WANG H, et al. A DEM super-resolution reconstruction network combining internal and external learning [J]. *Remote Sensing*,2022,14(9):2181.
- [16] HE P, CHENG Y M, QI M D, et al. Super-resolution of digital elevation model with local implicit function representation [C]//2022 international conference on machine learning and intelligent systems engineering (MLISE). Guangzhou: IEEE, 2022:111-116.
- [17] ZHANG Y, YU W, ZHU D. Terrain feature-aware deep learning network for digital elevation model superresolution [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 189:143-162.
- [18] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks [C]//Proceedings of the IEEE international conference on computer vision. Venice: IEEE, 2017:764-773.
- [19] ZHOU A, CHEN Y, WILSON J P, et al. A multi-terrain feature-based deep convolutional neural network for constructing super-resolution DEMs [J]. *International Journal of Applied Earth Observation and Geoinformation*,2023,120:103338.
- [20] JIANG Y, XIONG L Y, HUANG X, et al. Super-resolution for terrain modeling using deep learning in high mountain Asia [J]. *International Journal of Applied Earth Observation and Geoinformation*,2023,118:103296.
- [21] YAO S, CHENG Y, YANG F, et al. A continuous digital elevation representation model for DEM super-resolution [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2024,

- 208;1-13.
- [22] 张宏鸣,全凯,杨亚男,等. 基于深层残差网络的山区DEM超分辨率重构[J]. 农业机械学报,2021,52(1):178-184.
- [23] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]//European conference on computer vision. Munich; Springer, 2018; 294-310.
- [24] DAI Y, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion[C]//Proceedings of the IEEE/CVF winter conference on applications of computer vision. Waikoloa; IEEE, 2021; 3560-3569.
- [25] 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. Las Vegas; IEEE, 2016; 770-778.
- [26] SHI W, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas; IEEE, 2016; 1874-1883.
- [27] ZHU X, HU H, LIN S, et al. Deformable convnets v2; more deformable, better results[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach; IEEE, 2019; 9308-9316.
- [28] WANG W, DAI J, CHEN Z, et al. Internimage: exploring large-scale vision foundation models with deformable convolutions[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Vancouver; IEEE, 2023; 14408-14419.
- [29] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu; IEEE, 2017; 4681-4690.
- [30] MA Xiaochuan, LI Houpu, CHEN Zhanlong. Feature-enhanced deep learning network for digital elevation model super-resolution[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16; 5670-5685.
- [31] HAN D. Comparison of commonly used image interpolation methods[C]//2nd international conference on computer science and electronics engineering (ICCSEE 2013). Hangzhou; Atlantis Press, 2013; 1556-1559.
- [32] DONG Chao, LOY Chen Change, HE Kaiming, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2); 295-307.
- [33] WANG S, REHMAN A, WANG Z, et al. SSIM-motivated rate-distortion optimization for video coding[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2011, 22(4); 516-529.