以特征线和高程范围为约束的 DEM-cGAN 框架

江西林^{1,2)}, 王少荣^{1,3,4)*}, 李文玉^{2,5)}, 汪国平^{4,6)}

¹⁾ (北京林业大学信息学院 北京 100083)

²⁾ (北京大学软件与微电子学院 北京 102600)

³⁾ (国家林业草原林业智能信息处理工程技术研究中心 北京 100083)

⁴⁾ (北京大学北京市虚拟仿真与可视化工程技术研究中心 北京 100871)

⁵⁾ (山东大学机电与信息工程学院 威海 264209)

⁶⁾ (北京大学图形与交互技术实验室 北京 100871)

(shaorongwang@hotmail.com)

摘 要: 目前大规模地形生成方法依赖传统数学方法, 缺乏用户控制, 实现难度较大. 尽管深度学习技术已介入地形生成工作中, 但缺少相关的训练数据集, 且未对经典生成网络的固有缺陷作出改进. 为了获得真实感更强的地形数据, 构建了一个由地形特征草图、地形灰度图像、高程分割图像和高程模型组成的数据集, 并提出以特征线和高程范围为约束的 DEM-cGAN 框架, 设计了一个双尺度并行生成网络 ParallelGen. 用户通过输入地形特征草图及高程范围, 利用 DEM-cGAN 获得完整的高程数据. 对生成结果从视觉效果、数值分析和地理学层面进行多项实验的结果表明, DEM-cGAN 框架能正确地生成最大栅格尺寸为 512×512 像素的高程数据, 并还原特征草图中的起伏走势, 符合现实中的地理学规律.

关键词: 数字高程模型生成; 深度学习; 条件式生成对抗网络; 地形特征

中图法分类号: TP391.41

DOI: 10.3724/SP.J.1089.2021.18656

DEM-cGAN Framework Constrained by Feature Lines and Elevation Range

Jiang Xilin^{1,2)}, Wang Shaorong^{1,3,4)*}, Li Wenyu^{2,5)}, and Wang Guoping^{4,6)}

¹⁾ (School of Information Science and Technology, Beijing Forestry University, Beijing 100083)

²⁾ (School of Software and Microelectronic, Peking University, Beijing 102600)

³⁾ (Engineering Research Center for Forestry-oriented Intelligent Information Processing of National Forestry and Grassland Administration, Beijing 100083)

⁴⁾ (Virtual Simulation and Visualization Engineering Center, Peking University, Beijing 100871)

⁵⁾ (School of Mechanical, Electrical and Information Engineering, Shandong University, Weihai 264209)

⁶⁾ (Graphics Labs of EECS, Peking University, Beijing 100871)

Abstract: Currently, large-scale terrain generation methods still rely on traditional mathematical algorithms, which lack user's control and are difficult to be realized. Although deep learning techniques have been used in terrain generation, the related training datasets are not publicly available and the inherent defects of classical generative networks have not been improved. To obtain more realistic terrain data, a terrain dataset consisting of feature sketches, grayscale images, elevation segmentation images, and elevation models is created. Also, DEM-cGAN framework constrained by feature lines and elevation range is proposed, and a dual-scale parallel

收稿日期: 2020-09-14; 修回日期: 2020-12-01. 基金项目: 国家重点研发计划(2017YFB1002705); 中央高校基本科研业务费专项(2015ZCQ-XX). 江西林(1998—), 女, 硕士研究生, CCF 学生会会员, 主要研究方向为计算机图形学、深度学习; 王少荣(1975—), 男, 博士, 讲师, 硕士生导师, CCF 会员, 论文通讯作者, 主要研究方向为计算机图形学、虚拟现实; 李文玉(1998—), 女, 硕士研究生, 主要研究方向为计算机图形学、深度学习; 汪国平(1964—), 男, 博士, 教授, 博士生导师, CCF 会员, 主要研究方向为计算机图形学、虚拟现实、人机交互.

network ParallelGen is designed. Users can obtain elevation data with DEM-cGAN by sketching the terrain feature lines and giving the elevation range. Multiple experiments are conducted on the generated results at the visual, numerical, and geographic levels. The results show that, DEM-cGAN framework can correctly generate elevation data with a maximum raster size of 512×512 . And the results reproduce the undulation trend in the feature sketch and conform to the realistic geographic laws.

Key words: digital elevation model generation; deep learning; conditional generative adversarial networks; terrain feature

大规模地形生成广泛应用于游戏引擎和虚拟战场等场景中. 传统的地形生成方法主要有过程式^[1-4]、样本式^[5-7]和仿真式^[8-11]等; 但这 3 类方法均缺少用户对地形生成的控制, 其中, 样本式方法难以自发地生成新地形样式, 仿真式方法则伴随着昂贵的计算成本^[12]. 此外, 传统方法的实现过程往往烦琐, 学习入门门槛高. 因为用于指导地形生成的信息大多是针对地形特征的描述, 非特征区域得不到详细的描述, 所以生成的地形真实度不高^[13].

目前, 基于深度学习的地形生成工作主要包含 2 个方向: (1) 基于数字高程模型(digital elevation model, DEM)的地形特征. 地形特征要素是指对地表形态起到控制作用的点、线和面状特征, 它们共同构成了地表形态的基本骨架^[13]. 例如, 山顶点是流域内最高点, 鞍部点是分水线上的局部最小值, 山脊线和山谷线具有明显的汇水特征^[14], 正负地形区域是我国西南部地区中重要的面状特征^[15-16]等. (2) 基于生成对抗网络(generative adversarial networks, GAN)的方法^[17]. GAN 方法包含 2 个模型: 学习数据分布的生成模型 G 和估计样本来自训练集的概率的判别模型 D ^[17]. 基于 GAN, Mirza 等^[18]提出条件式生成对抗网络(conditional GAN, cGAN), 将模型的训练方式转变为有监督模式. 基于 cGAN, Isola 等^[19]提出图像间的转换网络 pix2pix. 基于 pix2pix, Wang 等^[20]提出一种适用于高分辨率图像生成和语义编辑任务的 pix2pixHD 网络. 但是, 已有的基于地形特征和 cGAN 的地形生成工作^[12-13]中均未公开实际使用的训练集, 且都使用基于 pix2pix 的生成框架, 未对 pix2pix 固有的结构缺陷作出改进, 最终生成的地形效果需要额外的编辑和修正.

为了使地形生成过程更加便捷与可靠, 本文构建了一个由地形特征线、地形灰度图像、地形高程分割图像和 DEM 数据构成的数据集, 借鉴经典

的图像生成网络, 提出一种适合 DEM 生成的双尺度并行生成网络 ParallelGen, 并利用该网络实现了一个以地形特征线和高程范围为约束条件的 DEM-cGAN 框架. 该框架实现了凭借有限的地形特征信息和高程范围重建出高保真度地形的目标.

1 DEM-cGAN 框架

1.1 DEM 生成要素

DEM-cGAN 框架用到的各数据要素如图 1 所示.

图 1 地形生成要素展示

(1) 地形特征草图. 地形的线状特征能极好地描述地形的大致走势. 因此, 本文选取山脊线与山谷线, 并将二者转换为草图形式, 作为 DEM 生成流程中的初始约束条件. 具体样例如图 1a 所示.

(2) 地形灰度图像. 灰度图像是常用的高程表现形式, 它使用线性函数将原高程范围变换至灰度颜色范围, 越大(小)的高程越接近白(黑)色. 具

体样例如图 1b 所示。

(3) 地形高程分割图像. 为了以图像的形式存储 DEM 的真实高程信息, 本文按照一定的间隔, 利用多个等高线对高程值进行划分, 且各个划分区域间的颜色相互独立且不重复. 具体样例如图 1c 所示。

(4) 地形高程标签. 借鉴独热码的思想设计并制作了地形高程标签, 用于存储用户设计目标的高程范围信息, 作为新的隐式地形生成约束条件. 地形高程标签的制作流程见第 2.1 节。

1.2 DEM 生成流程

本节将说明数据要素间是如何相互影响与作用的. DEM-cGAN 框架的完整训练流程如图 2 所示, 包含 3 个步骤:

Step1. 输入地形特征草图, 生成地形灰度图像, 以获取地形的总体起伏状况。

Step2. 输入地形灰度图像, 在网络中间层融入地形高程标签, 生成地形高程分割图像。

Step3. 输入地形高程分割图像, 生成 DEM 数据。

其中, Step1 和 Step3 中的生成网络结构完全一致; Step2 中的生成网络在中间层上增加了一个标签融合的操作, 目的是将高程范围标签作为约束条件限制高程分割图像的生成效果。

图 2 DEM-cGAN 框架

因为地形特征草图包含的信息有限, 且不同地区的地形跨越的高程范围也各不相同, 容易造成无法正确地拟合高程值分布的问题, 所以不直

接根据地形特征草图生成 DEM 数据. 而地形灰度图像间的内容指向具有一致性, 因此首先生成地形灰度图像能确保内容的正确性。

与已有工作相比, DEM-cGAN 增加了 Step2 和 Step3; 缺少 Step2, 即将地形灰度图像映射回高程值时会损失一定的高程精度, 使地形的三维效果缺少细节而变得表面平滑. 为了弥补这一点, 本文结合用户期望的最终高程范围, 将地形灰度图像转换为地形高程分割图像; 且高程分割图像的精度取决于用户对高程标签的等高间隔值, 间隔值越小, 被划分的区域就越多, 但应保证等高区域呈面状而非点状, 否则会严重影响模型的特征提取能力而导致失败。

经过 Step2 得到的高程分割图像既具备正确的高程内容, 又包含了实际的高程范围信息. 因此, Step3 应输入地形高程分割图像生成 DEM 数据. 每个划分区域的颜色只能对应指定范围内的高程值, 更有利于生成合理的 DEM 数据. 此外, 由于地形高程分割图像对于用户交互极其不便捷, 因此为了降低交互复杂度, 在实际使用时, 图 2 中的所有中间过程均对用户不可见, 用户只需提供地形特征草图和地形高程标签。

1.3 网络训练过程

为了生成具有真实感的 DEM 数据, 需要单独训练图 2 中各步骤的生成网络, 以保证每部分生成网络能完美地处理各自阶段的任务. 以图 2 中的 Step2 为例, 其具体的训练策略如图 3 所示. 生成网络 G 接收地形灰度图像作为输入, 并融入地形

图 3 网络训练过程

高程标签于网络中间的特征提取层,以产出符合高程范围的地形高程分割图像.将地形灰度图像分别与生成值和真实值连接后,分2次送入判别网络 D 中, D 负责对输入的样本进行真伪判断.按照此流程,排除地形高程标签部分,对图2中的其余2个生成网络进行训练.

1.4 双尺度并行的生成网络 ParallelGen

pix2pixHD的生成网络采用双子网结构,很好地解决了高分辨率图像的生成难题,其中,使用 G_1 表示全局生成网络, G_2 表示局部增强网络. G_1 的内部结构与文献[21]中的图像转换网络结构一致,由下采样、残差块^[22]组和上采样组成.借鉴这2项工作,本文改进并提出如图4所示的双尺度并行的生成网络 ParallelGen.

图4 ParallelGen网络结构

(1) 网络结构.如图4所示,ParallelGen由子网 G_{big} 和 G_{small} 构成,这2个子网结构与pix2pixHD中的 G_1 结构相同.其中, G_{big} 接收条件约束项为输入,并利用最大池化层对该条件项进行2倍下采

样,得到的结果输入 G_{small} .这样即可保留主要特征信息,在减少运算量的同时又增大了卷积核感受野,更利于提取高层语义. G_{big} 的输出尺寸与 G_{small} 的相同,将这2个输出进行融合后再进行最后一次反卷积,即可得到最终生成结果.高程标签根据实际尺寸大小,选择性地融入 G_{big} 下采样的某一特征层中.

(2) 损失函数.一般cGAN的损失函数剔除噪声项 z 后的结果为

$$L_{cGAN}(G, D) = E_{x,y}[\ln(D(x, y))] + E_x[\ln(1 - D(x, G(x)))] \quad (1)$$

在式(1)的生成损失基础上,ParallelGen的损失函数增加了2项 L_1 损失函数,即

$$L_G = \arg \min_G L_{cGAN}(G, D) + \lambda_1 L_{1_norm}(G) + \lambda_2 L_{1_elev}(G) \quad (2)$$

其中, L_{1_elev} 和 L_{1_norm} 分别表示高程值归一化前后的 L_1 损失; λ_1 和 λ_2 分别是这2项 L_1 损失的权重; L_{1_elev} 项只在训练过程的Step3中使用.

文献[19]已经证明, L_1 损失能在原cGAN基础上有效地减少结果中的模糊现象.其计算公式为

$$L_1 = \sum_{i=1}^n |S_{real} - S_{gen}| \quad (3)$$

其中, S_{real} 和 S_{gen} 分别表示真实样本和生成样本.

(3) 网络优势.文献[23]说明了双尺度思想足以解决许多视觉问题.ParallelGen中, G_{small} 负责提取全局特征, G_{big} 负责用于捕捉局部细节,二者融合后能相互修正补充,使最终生成结果的内容完整.此外,每个子网的下采样部分,能够在不增加计算成本的前提下构建更庞大的网络;且下采样能增大输出像素的有效感受野范围,以便更连贯地生成大部分内容^[21].残差块组解决了网络准确度因逼近饱和而急剧退化的问题,使得网络更轻易地学习确定的函数^[22].

1.5 基于 PatchGAN 的判别网络

本文微调调整文献[19]提出的PatchGAN的判别网络结构,并使用其辅助完成ParallelGen的训练工作.

(1) 网络结构.如图5所示,PatchGAN首先分割 $M \times M \times C$ 的样本,若设块尺寸为 $N \times N \times C$,便可获得 $(M/N)^2$ 个数据块;再依次对这些数据块进行真伪判别;最后平均这 $(M/N)^2$ 个判别结果,作为最终的输出结果.每个数据块的判别都需经

过一个全卷积网络, 本文记此结构为 ConvDisc, 可单独作为一个判别网络使用, 此时的输入尺寸应为 $M \times M \times C$. ConvDisc 首先将样本与条件项在深度上进行连接并以此为输入, 随后对输入进行 n 次卷积下采样, 并在第 $n+1$ 次卷积后输出 $8 \times 8 \times 1$ 的可信分值图像(数值 1 和 0 分别表示可信程度的高低最值).

图 5 本文使用的 PatchGAN 结构

(2) 损失函数. ConvDisc 的损失函数为

$$L_D = \arg \max_D L_{cGAN}(G, D) + \lambda L_{MSE}(D) \quad (4)$$

在式(1)的基础上, 式(4)增加了均方误差(mean square error, MSE)损失. MSE 损失通过计算目标值与估计值间差平方的期望求出二者的偏差, 并在不断的优化中使得偏差逐渐缩小, 从而增强 ConvDisc 的判别能力. MSE 损失的计算公式为

$$L_{MSE} = \frac{1}{n} \sum_{m=1}^n [(p_{\text{real}} - p_{\text{ones}})^2 + (p_{\text{fake}} - p_{\text{zeros}})^2] \quad (5)$$

其中, p_{real} 和 p_{fake} 分别表示对真实样本和生成样本判别后得到的可信度图像; p_{ones} 和 p_{zeros} 分别为可信度为 1 与为 0 的目标值图像. 计算得到的损失值将作为正则项输入生成网络中作为误差修正, 以达到激励生成网络的目的^[13]. PatchGAN 的损失函数是对 $(M/N)^2$ 个 ConvDisc 损失平均后的结果.

2 实验与结果分析

2.1 数据集

(1) 数据来源. 本文使用的 DEM 数据来源如下: 中国科学院计算机网络信息中心地理空间数据云平台^①, 选用 GDEM V2 30 M 分辨率数字高程数据; 美国国家航空航天局主导的航天飞机雷达地形测绘任务(shuttle radar topography mission,

SRTM)^[24]所采集的 SRTM1 数据. 这 2 种 DEM 数据的像素尺寸均为 $3\,600 \times 3\,600$, 空间分辨率为 30 m.

(2) 数据预处理. 首先对完整的 DEM 数据进行不重叠分割, 得到 256×256 和 512×512 这 2 种像素尺寸(简记为 256 和 512 分辨率)的 DEM 数据. 然后将分割后的数据转换为地形灰度图像(8 位灰度)和高程分割图像, 并人工剔除不符合要求的数据. 此外, 本文采用数据增强手段来扩充数据集量, 如图 6 所示. 具体方法如下: 对 DEM 数据进行高程值反转, 反转后的 DEM 数据对应的地形灰度图像是原灰度图像的反相结果; 再对反转前后的 DEM 数据提取线状特征; 最后执行 3 种旋转和 2 种翻转的操作, 使最终的数据量为原始的 12 倍. 本文数据集数目情况如表 1 所示, 各分辨率下取 75% 的数据量为训练集, 余下的则为测试集.

图 6 数据增强示意图

表 1 数据集分配情况

分辨率/像素	训练集/幅	测试集/幅	总计/幅
256×256	5 130	1 710	6 840
512×512	2 794	932	3 726

(3) 特征提取. 本文使用专业的地理科学数据处理软件提取 DEM 的山脊线和山谷线. 为了使二者能同时对地形起到描述作用, 将这 2 种线条融合到一幅背景为纯黑色的图像中, 并用红色表示山脊线, 蓝色表示山谷线.

(4) 高程标签制作. 独热码常用于表示拥有有限个可能值的离散特征量, 使用 n 个比特位表示 n 种不同的状态, 这 n 个比特值只有一个为 1, 其余均为 0. 本文设计了地形高程标签, 利用比特位表示地形高程间隔值. 不同于独热码, 高程标签可

① <http://www.gscloud.cn>

以有多个为 1 的比特位, 且其维度不再是 $(n, 1)$, 而是 $(n, n, 1)$, 目的是能够将标签直接融入生成网络中. 图 7 所示为地形高程标签的制作流程.

图 7 地形高程标签制作流程

2.2 网络训练配置

在实际训练过程中, 对各阶段的生成任务采用 ParallelGen 网络(简记为 ParaG), 判别网络会根据实际情况选择 ConvDisc(简记为 ConvD)或 PatchGAN(简记为 PatchG).

针对 256 和 512 这 2 种分辨率, PatchG 的块尺寸分别设为 64 和 128. 设批量值为 12, 使用 Adam^[25] 优化器(学习率为 0.002, 动量 $\beta_1 = 0.5$, $\beta_2 = 0.999$). 硬件环境为一台配有一块 GeForce RTX 2080 显卡的计算设备, 在 256 分辨率上训练单个 epoch 耗时 30s, 在 512 分辨率上为 100s.

2.3 地形灰度图像生成效果

生成地形灰度图像是 DEM 生成的首要步骤, 其生成质量直接决定了后续生成任务的表现. 因此, 在验证地形灰度图像的生成效果时, 本文视基于 pix2pix 的网络以及 pix2pixHD 中的 G_1 子网为基准网络, 将本文结果与这二者进行比较. 图 8 和图 9 分别展示了在 256 和 512 分辨率的测试集上, 使用 ParaG 得到的地形灰度图像与基准网络生成结果的对比.

从图 8 可以看出, 使用 pix2pix 时, 其生成结果中存在大量的模糊信息, 细节缺失严重, 不符合

真实地形灰度图应有的特征. 此时, 增加生成网络的深度会有轻微的改善作用, 但一味地加深对效果提升有限, 网络的生成结果较 pix2pix 保留下了更多的细节, 但与真实值相比存在较大差距. 作为对比, 本文的 ParaG 获得的结果无论是从整体上还是局部细节上都远优于对比方法结果, 特征线周围的细节层次更加丰富, 其真实感效果更好. 在 512 分辨率上, 由于使用 G_1 作为生成网络得到的结果彻底失败, 故不放在此处进行无意义的对比. 从图 9 可以看出, pix2pix 的结果的最主要问题在于细节缺失. 难以应用于实际问题. 本文方法的结果相较前者有了显著的改善, 整体地形走势与特征草图更为吻合, 灰度信息分布与真实值更为接近.

图 8 256 分辨率上地形灰度图像生成结果对比

此外, 本文使用结构相似性(structural similarity, SSIM)^[26]、余弦相似性(cosine similarity, Cosine)^[27]和直方图距离中的皮尔逊相关系数(Pearson correlation coefficient, Pearson)^[28] 3 种相似性指标,

评价不同网络生成的地形灰度图像. 3 种指标的计算结果如表 2 所示, 表中各值均为每幅生成图像的相似性求和后的均值. 在 256 分辨率上, 本文方法在 SSIM 和 Cosine 上获得了最优评价结果, 并与其他结果存在一定差距; 在 Pearson 系数上的评价虽不是最优, 但与最优值间的差距较小, 主要原因是小尺寸图像的内容有限, 导致灰度色彩信息差异不鲜明. 在 512 分辨率上, 本文方法在 3 项评价指标中均为最优结果. 综上所述, 本文提出的网络结构能有效地生成高质量的地形高程灰度图像.

图 9 512 分辨率上地形灰度图像生成结果对比

表 2 不同分辨率下地形灰度图像相似性实验结果

相似性 指标	256×256 像素			512×512 像素	
	ParaG ConvD	pix2pix	G_1 ConvD	ParaG PatchG	pix2pix
SSIM	0.815 1	0.769 2	0.761 3	0.912 2	0.826 7
Cosine	0.981 5	0.970 2	0.972 6	0.986 4	0.957 4
Pearson	0.461 4	0.465 3	0.472 1	0.734 3	0.629 5

2.4 地形高程分割图像生成效果

生成地形高程分割图像是整个 DEM 生成流程的中间步骤. 若能在地形灰度图像和高程标签的共同作用下生成符合用户条件约束的高程分割图像, 就能精准地生成 DEM 数据. 第 2.3 节已证实

pix2pix 与 G_1 网络生成的地形灰度图像真实感较差, 因此, 本节仅对比本文方法得到的结果与真实值间的效果差异.

本文使用的数据集的高程范围为 300~3300 m, 保证了每种颜色只对应单一范围内的高程值, 更利于训练生成网络. 对应的划分区域调色板信息如图 10 所示.

图 11 所示为在 256 分辨率上, 使用 ParaG 生成的高程分割图像与真实值间的对比效果. 可以看出, ParaG 生成结果较好地还原了真实的高程, 达到本文生成任务的应用需求. 对于真实值中相邻区域颜色变化分明的边界, 对应生成值的边界存在模糊现象, 原因是真实值是根据实际高程值获取到的, 而生成网络学习的是数据集中所有等高区域图像的综合, 因此单个生成结果不可能与

图 10 本文使用的高程分割调色板

图 11 256 分辨率上地形高程分割图像生成结果

真实值完全一致。

相比之下,在 512 分辨率上生成地形等高区域图像时,边界模糊的问题得到了明显改善,更加容易区分不同的高程区域色块。如图 12 所示,生成结果仍保留了大致的高程区域信息,在细节处存在个别颜色不一致的情况,这可能导致生成的地形高程模型的范围被拉伸或压缩。但各色块之间过渡较为自然,不会产生某片区域与周围有巨大落差的断层现象,考虑神经网络自身的二次创造能力,该误差是可以被接受的。

图 12 512 分辨率上地形高程分割图像生成结果

2.5 地形高程模型生成效果

图 13 和图 14 展示了生成的 DEM 数据与真实值间的对比情况,图中的渲染颜色由地形高程值进行分配。测试集中的地形大多属于山地,其最显著的特征就是地形起伏明显,变化剧烈。图 13 和图 14 中的真实样本符合对山地的描述,且海拔范围均在 900~2200m,属于中山类型。更进一步,本文将地形灰度图像进行三维渲染,以作为实验结果的对比项。

从图 13 可以看出,本文方法的结果很好地保持了山脉走势与表面起伏情况,较为精准地表达出了山地的典型特征,并且地形符合地理空间结构;而图 13c 和图 13d 的结果只保留了地形应有的起伏趋势,地表细节信息大多丢失。从图 14 可以看出,本文方法的生成结果在 512 分辨率上的表现同样有效,而 pix2pix 方法得到的结果除丢失细节信息外,还改变了地形凹陷区域应有的宽度与深度。

图 13 256 分辨率上地形高程模型生成结果对比

图 14 512 分辨率上地形高程模型生成结果对比

本文方法在各种分辨率下生成结果的高程范围与真实范围十分接近,对于不同的应用场景需要及时调整地形高程标签的高程间隔,以适应不同的精度要求。

2.6 地形高程数据统计情况

为了更加直观地量化本文方法获得的 DEM 结果与真实值间的匹配度,本文参考文献[29]的方法,分别选取 2 种分辨率下各 100 个测试集样本,统计每个生成样本与各自真实样本的高程最大值 $V_{\max}$, 最小值 $V_{\min}$, 均值 V_{mean} 和标准差 V_{std} 情况,统计结果如图 15 所示。可以看出,在 256 分辨率上,生成值与真实值的高程分布情况匹配度极高;

图 15 地形高程数据统计情况

而在 512 分辨率上的匹配情况较弱一些, 部分生成样本的高程最值与真实值存在一定差距. 但这对三维模型的视觉效果影响并不明显, 足以应用到一般场景中. 上述统计情况直接证明了本文方法的可行性, 也从侧面反映了高程范围约束的能力不够强, 后续工作中应着重加强这一点.

2.7 地形因子对比结果

坡度和坡向是极其重要的 2 个地形因子, 坡度反映了地表起伏变化率或陡峭程度, 坡向则反映了地貌的发展方向^[13], 本文从这 2 个角度阐释地形质量.

在坡向图的渲染设置中, 分别设置东南西北 4 个正方向的坡向颜色为橙色、黄色、绿色和红色. 在设置坡度图时, 大的坡度渲染范围会导致效果过于杂乱, 难以对比分析. 因此, 本文只保留 $0^{\circ} \sim 25^{\circ}$ 的坡度, 通过局部推理出全局情况. 坡向和坡度的对比图如图 16 和图 17 所示.

从图 16 可以看出, 本文方法生成结果的坡向走势与真实值相近; 但无论是哪种分辨率, 都可以发现生成结果的坡向变化更少一些, 坡向的过渡变化不够平滑, 原因在于高程模型的生成值与真实值本身存在一定偏差, 因此生成的地表细节的高程细节不够丰富. 从图 17 可以看出, 本文方法生成结果的坡度图整体上能较好地与真实值相匹配; 但同时存在着更多的小坡度, 即坡度大于或等于 25° 的区域变少了, 意味着生成的高程模型的地表坡势较为平缓. 如果 DEM 结果中不存在错误信息, 就能认为其对应的坡向和坡度是正确的.

图 16 地形坡向图对比

2.8 地形特征保持能力对比

对生成的 DEM 数据提取山脊线与山谷线, 并与原始输入的特征线进行比较, 是验证生成前后特征保持情况的有效手段^[13]. 本文采用第 2.1 节的

图 17 地形坡度图对比

特征提取方法对 2 种分辨率下的生成结果提取山脊线与山谷线,并将特征线附着于山体阴影渲染后的图像中。

分析图 18 可知,实际的地形特征与各个二次提取的特征均较为吻合,表明生成的地形很好地保持了地形的山脊山谷形状,严格遵循了输入的地形特征;尽管在局部细节上存在偏差,但并没有对地形结果产生不良影响。这也间接证明了 ParaG 是适合 DEM 生成任务的。

3 结 语

本文构建了一个由多类地形因子数据与 DEM 组成的数据集,其中包含众多地形要素,弥补了用于训练 DEM 生成网络的基础数据集;此外,本文提出的 DEM-cGAN 框架成功地将地形特征草图和高程标签作为 DEM 编辑因子。本文同时为 DEM-cGAN 设计了一个双尺度并行的生成网络 ParallelGen,用于处理 DEM-cGAN 中各阶段的生成任务,使各项生成结果均与真实效果十分接近,

图 18 地形特征保持能力对比

能应用于最大 512 分辨率的 DEM 生成流程中。

但是,本文中的特征草图只包含线状特征,特征表达能力不够强;欠缺对不同高程间隔的高程标签的自适应,每次修改高程间隔后都需重新训练;实现的地形范围受限于 512 分辨率。今后应考虑加入更具代表性的地性约束条件,在简化 DEM 生成流程的同时进一步提升 DEM 的生成质量。

致谢 感谢北京大学图形与交互技术实验室博士研究生胡志明对本文写作提出的建议。

参考文献(References):

- [1] Mandelbrot B B, van Ness J W. Fractional Brownian motions, fractional noises and applications[J]. SIAM Review, 1968, 10(4): 422-437
- [2] Lv Xiuqin, Zhang Yi. Application of fractal simulation in DEM interpolation[J]. Science of Surveying and Mapping, 2012, 37(2): 107-109(in Chinese)
(吕秀琴, 张毅. 分形模拟在 DEM 内插中的应用[J]. 测绘科学, 2012, 37(2): 107-109)

- [3] Yu Fei, Chen Feinan, Ma Hui, *et al.* Application of complex fractal interpolation algorithm in seabed terrain simulation[J]. *Computer Simulation*, 2015, 32(1): 254-258(in Chinese)
(于飞, 陈斐楠, 马慧, 等. 复合分形插值算法在海底地形仿真中的应用[J]. *计算机仿真*, 2015, 32(1): 254-258)
- [4] Cheng Yi. Simulation of the natural landscape based on fractal[D]. Taiyuan: North University of China, 2011(in Chinese)
(程义. 基于分形的自然景观模拟[D]. 太原: 中北大学, 2011)
- [5] Zhou H, Sun J, Turk G, *et al.* Terrain synthesis from digital elevation models[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2007, 13(4): 834-848
- [6] Gain J, Marais P, Straßer W. Terrain sketching[C] // *Proceedings of the Symposium on Interactive 3D Graphics and Games*. New York: ACM Press, 2009: 31-38
- [7] Tasse F P, Gain J, Marais P. Enhanced texture-based terrain synthesis on graphics hardware[J]. *Computer Graphics Forum*, 2012, 31(6): 1959-1972
- [8] Musgrave F K, Kolb C E, Mace R S. The synthesis and rendering of eroded fractal terrains[J]. *Computer Graphics*, 1998, 23(3): 41-50
- [9] Nagashima K. Computer generation of eroded valley and mountain terrains[J]. *Visual Computer*, 1997, 13(9): 456-464
- [10] Chiba N, Muraoka K, Fujita K. An erosion model based on simulated velocity fields for visually simulating mountain scenery[J]. *The Journal of Visualization and Computer Animation*, 1998, 9(4): 185-194
- [11] Peytavié A, Galin E, Grosjean J, *et al.* Arches: a framework for modelling complex terrains[J]. *Computer Graphics Forum*, 2009, 28(2): 457-467
- [12] Guérin É, Digne J, Galin É, *et al.* Interactive example-based terrain authoring with conditional generative adversarial networks[J]. *ACM Transactions on Graphics*, 2017, 36(6): Article No.228
- [13] Li Ke. Virtual terrain generation based on deep learning[D]. Nanjing: Nanjing Normal University, 2019(in Chinese)
(李可. 基于深度学习的虚拟地形生成方法研究[D]. 南京: 南京师范大学, 2019)
- [14] Zhu Qing, Zhao Jie, Zhong Zheng, *et al.* The extraction of topographic patterns based on regular grid DEMs[J]. *Acta Geodaetica et Cartographica Sinica*, 2004, 33(1): 77-82(in Chinese)
(朱庆, 赵杰, 钟正, 等. 基于规则格网 DEM 的地形特征提取算法[J]. *测绘学报*, 2004, 33(1): 77-82)
- [15] Li Yang, Zhou Yi, Lei Xue, *et al.* Simulation of quantitative relationship between positive and negative topographic factors of loess based on catchment unit[J]. *Journal of Arid Land Resources and Environment*, 2019, 33(7): 78-84(in Chinese)
(李阳, 周毅, 雷雪, 等. 基于流域单元的黄土地貌正负地形因子量化关系模拟[J]. *干旱区资源与环境*, 2019, 33(7): 78-84)
- [16] Li Jingxin, Xu Erqi. Extraction of positive and negative terrain boundary in Karst region of southwest China[J]. *Resources Science*, 2017, 39(10): 1989-1999(in Chinese)
(李婧昕, 许尔琪. 中国西南喀斯特地区正负地形的提取方法研究[J]. *资源科学*, 2017, 39(10): 1989-1999)
- [17] Goodfellow I J, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial networks[C] // *Proceedings of the Advances in Neural Information Processing Systems*. Cambridge: MIT Press, 2014: 2672-2680
- [18] Mirza M, Osindero S. Conditional generative adversarial nets[OL]. [2020-09-14]. <https://arxiv.org/pdf/1411.1784.pdf>
- [19] Isola P, Zhu J Y, Zhou T, *et al.* Image-to-image translation with conditional adversarial networks[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2017: 5967-5976
- [20] Wang T C, Liu M Y, Zhu J Y, *et al.* High-resolution image synthesis and semantic manipulation with conditional GANs[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2018: 8798-8807
- [21] Johnson J, Alahi A, Li F F. Perceptual losses for real-time style transfer and super-resolution[C] // *Proceedings of European Conference on Computer Vision*. Heidelberg: Springer, 2016: 694-711
- [22] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2016: 770-778
- [23] Brown M, Lowe D G. Recognising panoramas[C] // *Proceedings of the 9th IEEE International Conference on Computer Vision*. Los Alamitos: IEEE Computer Society Press, 2003: 1218-1225
- [24] Farr T G, Kubrick M. Shuttle radar topography mission produces a wealth of data[J]. *EOS Transactions American Geophysical Union*, 2000, 81(48): 583-585
- [25] Kingma D P, Ba J. Adam: a method for stochastic optimization[OL]. [2020-09-14]. <https://arxiv.org/pdf/1412.6980.pdf>
- [26] Wang Z, Bovik A C, Sheikh H R, *et al.* Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612
- [27] Singhal A. Modern information retrieval: a brief overview[J]. *IEEE Data Engineering Bulletin*, 2001, 24(4): 35-43
- [28] Meshgi K, Ishii S. Expanding histogram of colors with grid-ding to improve tracking accuracy[C] // *Proceedings of the 14th IAPR International Conference on Machine Vision Applications*. Los Alamitos: IEEE Computer Society Press, 2015: 475-479
- [29] Qiu Z H, Yue L W, Liu X G. Void filling of digital elevation models with a terrain texture learning model based on generative adversarial networks[J]. *Remote Sensing*, 2019, 11(23): 2829-2850