

武汉大学学报(信息科学版)

Geomatics and Information Science of Wuhan University

ISSN 1671-8860,CN 42-1676/TN

## 《武汉大学学报(信息科学版)》网络首发论文

题目： 基于自适应生成对抗网络的 DEM 超分辨率重建方法  
作者： 侯旭娟，邓筱瞳，花卫华，殷婉婷，李鹏，齐春雨  
DOI： 10.13203/j.whugis20240186  
收稿日期： 2024-11-18  
网络首发日期： 2024-11-26  
引用格式： 侯旭娟，邓筱瞳，花卫华，殷婉婷，李鹏，齐春雨. 基于自适应生成对抗网络的 DEM 超分辨率重建方法[J/OL]. 武汉大学学报(信息科学版).  
<https://doi.org/10.13203/j.whugis20240186>



**网络首发：**在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

**出版确认：**纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

DOI:10.13203/j.whugis20240186

引用格式：

侯旭娟, 邓筱瞳, 花卫华, 等. 基于自适应生成对抗网络的 DEM 超分辨率重建方法[J]. 武汉大学学报(信息科学版), 2024, DOI:10.13203/J.whugis20240186 (HOU Xujuan, DENG Xiaotong, HUA Weihua, et al. DEM Super-resolution Reconstruction Method Based on Adaptive Generative Adversarial Network[J]. Geomatics and Information Science of Wuhan University, 2024, DOI:10.13203/J.whugis20240186)

## 基于自适应生成对抗网络的 DEM 超分辨率重建方法

侯旭娟<sup>1</sup>, 邓筱瞳<sup>2</sup>, 花卫华<sup>1\*</sup>, 殷婉婷<sup>1</sup>, 李鹏<sup>3,4</sup>, 齐春雨<sup>3,4</sup>

1 中国地质大学(武汉)地理与信息工程学院, 湖北 武汉 430078

2 中国地质调查局成都地质调查中心, 四川 成都 610081

3 中国铁路设计集团有限公司, 天津 300308

4 城市轨道交通数字化建设与测评技术国家工程研究中心, 天津 300308

**摘要：**数字高程模型(Digital elevation model, DEM)作为城市建模, 灾害评估, 三维可视化的数据基础, 其作为输入能够提高许多地理分析应用的准确性和可靠性。为了减少重建 DEM 中的伪影和噪声, 提高 DEM 超分辨率重建的精度, 本文研究了利用深度残差生成对抗网络进行 DEM 超分辨率重建的方法, 提出了一种结合自适应卷积和融合 U-Net 的生成对抗神经网络方法(SRDCGAN), 实现 4 倍分辨率提高的 DEM 超分辨率重建。对 DEM 的重建精度进行评估, 实验的四组数据集中, RMSE 均值下降了 0.3%-12.6%, MAE 均值下降了 3.2%-14.5%, Slope 均值下降了 1.9%-18.3%, Aspect 均值下降了 2.7%-12.0%。重建效果与双三次和 SRGAN 方法进行对比, SRDCGAN 方法能够有效去除伪影并保留更多地形特征, 重建精度 RMSE、MAE、Slope 和 Aspect 值都有显著提升。

**关键词：**数字高程模型; 超分辨重建; 自适应卷积; 生成对抗网络

## DEM Super-resolution Reconstruction Method Based on Adaptive Generative Adversarial Network

HOU Xujuan<sup>1</sup>, DENG Xiaotong<sup>2</sup>, HUA Weihua<sup>1\*</sup>, YIN Wanting<sup>1</sup>, LI

Peng<sup>3,4</sup>, QI Chunyu<sup>3,4</sup>

1 School of Geography and Information Engineering, China University of Geosciences(Wuhan), Wuhan 430078, China

2 Chengdu Center, China Geological Survey, Chengdu, 610081, China

3 China Railway Design Corporation, Tianjin 300308, China

收稿日期: 2024-11-18

基金项目: 湖北省重点研发计划项目(2022BCA080); 中国国家铁路集团有限公司科研专项(L2022G015); 西南地区自然资源督察技术支撑与应用服务(DD20230497)。

作者简介: 侯旭娟, 硕士, 现从事地形超分辨率重建、三维地质建模方向研究。15033655660@163.com。

通讯作者: 花卫华, 副教授。huaweihua@cug.edu.cn。

**Abstract: Objectives:** The Digital Elevation Model (DEM) serves as the data foundation for urban modeling, disaster assessment, and 3D visualization. As an input, it can improve the accuracy and reliability of many geographic analysis applications. **Methods:** To reduce artifacts and noise in the reconstruction of Digital Elevation Models (DEMs) and improve the precision of DEM super-resolution reconstruction, this paper proposes a generative adversarial network (GAN) super-resolution reconstruction model that integrates adaptive convolution and U-Net. (1) The generator's feature extraction module employs a deep residual dense module and an adaptive residual convolution module. The deep residual dense module reduces artifacts and noise generated during SRGAN reconstruction while increasing the receptive field and enhancing the model's feature extraction capability. (2) The adaptive convolution module introduces deformable convolution into the residual network module, enabling the network model to adaptively extract feature information and learn more terrain features. (3) The discriminator incorporates a U-Net structure with an attention mechanism, where U-Net demonstrates good performance and efficient utilization of GPU memory. The attention mechanism captures sufficiently large receptive fields to obtain semantic contextual information, thereby improving the reconstruction accuracy and learning efficiency of the DEM. (4) The proposed model effectively addresses issues such as edge smoothing in DEM reconstruction, the presence of artifacts and noise in reconstructions, and the omission of certain terrain features. **Results:** The reconstruction accuracy of the DEM is evaluated, and the four datasets of the experiment show a decrease of 0.3%-12.6% in the mean value of RMSE, 3.2%-14.5% in the mean value of MAE, 1.9%-18.3% in the mean value of Slope, and 2.7%-12.0% in the mean value of Aspect. The reconstruction results are compared with the double-three times and SRGAN methods, and the SRDCGAN method can effectively remove the artifacts and retain more terrain features, and the reconstruction accuracy of the RMSE, MAE, Slope and Aspect values are significantly improved. **Conclusions:** The results indicate that the SRDCGAN method can establish a mapping model for high-resolution and low-resolution DEM data from a specific area. High-resolution DEMs from other regions can be reconstructed using the mapping model with low-resolution DEMs. SRDCGAN is expected to achieve high practical value in geological applications that utilize high-resolution DEMs.

**Key words:** Digital elevation model; Super-resolution reconstruction; Adaptive convolution; Generative adversarial network

数字高程模型 (Digital elevation model, DEM) 是利用有限的高程数据实现对地球表面的数字化模拟。高分辨率 DEM 提供了准确的基础地理数据<sup>[1]</sup>, 被广泛应用在城市建模、灾害评估<sup>[2]</sup>、水文建模、军事战略等领域, 而在实际应用中, 由于高分辨率 DEM 的高保密性以及获取技术的限制, 往往获取成本极高或难以获取。不少高分辨率 DEM 在数据采集和生成的时候, 会产生系统误差, 存在数据缩减等问题<sup>[3]</sup>。

为了能够高效低成本的获取较准确的高分辨率 DEM 数据, 研究学者们主要提出了两类方法: 基于传统的方法和基于深度学习的方法。基于传统的方法主要有插值、回归和多尺度融合的方法。其中插值方法主要有双线性<sup>[4]</sup>、B 样条<sup>[5]</sup>、双三次<sup>[6]</sup>、克里金<sup>[7]</sup>和距离逆加权等, 这类基于预定义的数学公式计算插值算法的优点在于计算量小, 复杂度低, 重建速度快, 但是得到的图像过于平滑, 有振铃和锯齿伪影, 导致在高频信息区域的重建性能较差。而回归和融合的方法, 虽然能够学习到局部集合特征, 并学习到高频的信息, 但学习的质量受训练集影响较大, 可能导致捕获冗余或错误的特征。

深度学习的主要应用领域包括计算机视觉<sup>[8]</sup>、语音识别、自然语言处理<sup>[9]</sup>等领域, 包

括基于卷积神经网络（Convolutional Neural Network, CNN）<sup>[10]</sup>、深度残差网络、生成对抗神经网络等方法被应用到 DEM 超分辨率重建中。用深度学习技术对影像进行超分辨率重建的研究越来越多<sup>[11]</sup>。最初，基于 CNN 的方法被应用于 DEM 的超分辨率重建（SR）任务中，然而，用图像数据集训练的 CNN 在直接训练 DEM 时，无法达到预期的精度。在此之后，生成对抗网络方法是近十年来计算机视觉研究中的一大热门方法。Ledig 等人<sup>[12]</sup>在深度残差网络 ResNet 的基础上设计了一个含有感知损失函数的 SRGAN（超分辨率生成对抗网络）来实现 SISR，SRGAN 是第一个能够为 4 个放大因子推断照片般逼真自然图像的框架，这个网络能够在公共基准上从大量下采样的图像中恢复照片真实的纹理。Demiray 等人<sup>[13]</sup>在此基础上提出了一种基于 DEM 数据的 SRGAN 的方法 D-SRGAN，使给定 DEM 数据集的空间分辨率提高四倍，且不需要额外的数据相关信息。Zhou 等人<sup>[14]</sup>并提出了一种基于多地形特征的深度 CNN 用于超分辨率（SR）DEM（MTF-SR）。其实验结果显示了 MTF-SR 模型在整体高程精度和地形特征保留方面的优势。Zhang 等人<sup>[15]</sup>提出了一种地形特征感知超分辨率模型（TfaSR），以指导 DEM 的超分辨率朝向地形特征的提取和优化，TfaSR 在 DEM 超分辨率过程中实现了先进的地形特征保留性能。Zhang 等人<sup>[16]</sup>分别应用 CEDGAN<sup>[17]</sup>、SRGAN 和 ESRGAN<sup>[18]</sup>对 DEM 超分辨率重建进行了对比试验，实验得出 SRGAN 在一系列 DEM SR 实验中表现出最佳的准确性评估性能。由于 SRGAN 模型特征利用率不高，网络参数较多，可扩展性较差，BN 层又破坏了 DEM 中一些对比信息和网络的稳定性，导致普通的深度学习方法在 DEM 高分辨率重建中会产生大量伪影和噪声。

基于上述分析，为了减少重建 DEM 中产生的伪影和噪声，提高 DEM 超分辨率的重建精度，需要对其中的网络模型和权重计算方法进行改进。U-Net 卷积深度神经网络是一种高效的网络模型，通过权值共享和多重上采样可降低计算成本，提高收敛速度。为此，本文提出了一种自适应卷积和融合 U-Net 的生成对抗神经网络方法(SRDCGAN)，通过学习 DEM 中的高频信息，减少伪影和噪声，恢复地形特征，完善了 SRGAN 中的特征提取模块，改进了模型判别器，提高了模型的稳定性，改善了重建 DEM 的细节特征。

## 1 方法论

### 1.1 生成对抗神经网络基础框架

本文提出的 SRDCGAN 方法的基础技术流程如图 1 所示，首先预处理数据集，低分辨率 DEM 数据集通过批量用双线性插值的方法下采样 1/4 倍高分辨 DEM 得到，得到相互对应的高分辨率和低分辨率的数据集。SRDCGAN 方法基于 SRGAN 网络的基本的架构结构，分为生成器和判别器两个部分：通过生成器将低分辨率 DEM 重建到高分辨率 DEM，通过判别器对生成的 DEM 和原始高分辨率 DEM 进行比较，从而不断优化网络。

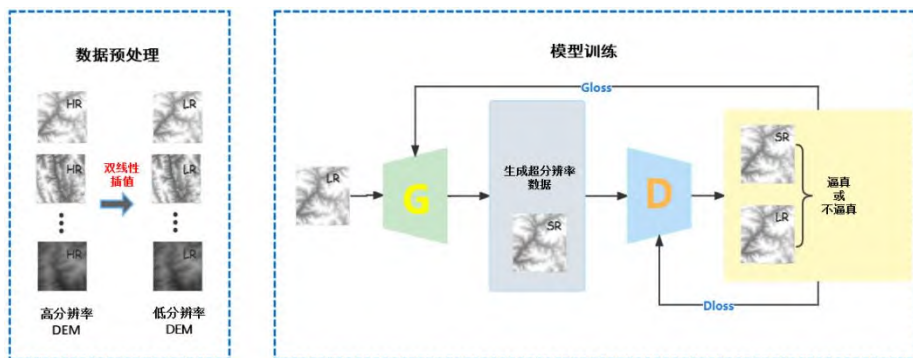


图 1 技术流程图

Fig.1 Technical flowchart

## 1.2 生成器特征提取模块

针对 SRGAN 模型重建产生大量伪影的噪声的问题，本文提出的 SRDCGAN 在生成器的特征提取模块中分别设计了深度残差密集模块和自适应地形特征提取模块。


### 1.2.1 深度残差密集模块

参考 ESRGAN 网络<sup>[18]</sup>的改进方式，使用深度残差密集模块（RRDB, Residual in Residual Dense Block）来负责学习 DEM 的全局特征信息，它的结构可以更好地深化网络的结构，更好地结合图像的输入信息进行综合恢复；密集分块结构可以有效去除伪影的影响，提高图片质量，连续的密集分块有利于增加网络容量，改善模型效果。


如图 2 所示，RRDB 整体结构是由三个密集残差模块（RDB, Residual Dense Block）<sup>[16]</sup>构成，将主干网络的输出与残差边叠加形成一个深度的密集残差模块。这种密集连通的卷积层能够提取丰富的局部特征，每一层 RDB 层都前后直接连接，利用 RDB 的局部特征融合自适应地学习局部特征，使学习训练更加有效、训练更加稳定。

RDB 结构相当于将传统残差块（RB, Residual Block）与传统的密集块（DB, Dense Block）相结合，与传统的 DB 模块不同，本文使用的 RDB 在 DB 的基础上去除其中的批量归一化层（BN, Batch Normalization），BN 层在训练期间用于加速训练并使用更高的学习率，使学习更容易。当训练和测试数据集的统计数据差异大，或者网络结构较深时，BN 层会产生不好的伪影，并且降低网络的泛化能力，导致训练不稳定。因此，去除了 BN 层来保证训练的稳定性的一致性，也减少了 BN 层计算量从而减少了图像处理器的内存使用。总的来说，去除 BN 层有助于提高泛化能力，减少计算复杂度和内存使用。

整体的 RDB 结构如下图 2，是基于传统 DB 的卷积层结构模式改进的密集残差模块（RDB）。包含五层卷积层，并用 Leaky ReLU 作为激活函数，通过密集连接来进行信息传递。由此结构特征，深度密集模块能够减少伪影和噪声的产生，并增加感受野的同时加强了模型特征提取的能力。



(a) 深度残差密集模块（RRDB）



(b) 密集残差模块（RDB）

图 2 深度残差密集模块（RRDB）和密集残差模块（RDB）

Fig.2 Residual in Residual Dense Block and Residual Dense Block

### 1.2.2 自适应地形特征提取模块

为了学习到更多地形的结构信息，本文结合了一种自适应的卷积结构来学习地形的结

构特征，参考传统残差网络结构将可变形卷积引入到残差模块中，将普通的卷积层改成用可变形卷积层<sup>[19]</sup>。

可变形卷积又称自适应卷积<sup>[20]</sup>，实际是在标准采样位置上增加偏移量，而偏移量由一个额外的标准卷积层来决定，这就保证了在训练过程中可以根据特征的形状来学习偏移量。使卷积核能在训练过程中根据地形特征来扩大学习范围，实现对地形结构的自适应学习。

利用可变形卷积层特殊的自适应特征采样卷积的特点，我们设计了一种将残差结构和自适应卷积相结合的自适应残差卷积模块，它包含两层可变形卷积，卷积核 $3\times 3$ ，使用 ReLU 作为激活函数层，用跳跃连接进行残差传递，整体结构如图 3。由此，特征提取网络可以学习采样任意形状的特征，从而自主提取地形特征信息。




图 3 自适应卷积结构和自适应残差卷积模块

Fig.3 Adaptive convolutional structure and Adaptive Residual Convolution Block

### 1.3 DEM 高分辨率重建模型的生成器框架

生成器结构参考 SRGAN 网络的整体框架，主要由特征提取模块以及亚像素卷积层组成，特征提取模块包含密集残差模块和自适应残差卷积模块，密集残差模块通过减少伪影，增强模型的泛化能力，并同时降低计算复杂度和内存使用，自适应残差卷积模块学习更多地形特征。

整体结构如图 4，首先通过 5 个深度密集残差模块，每个密集结构是密集连接的 5 层卷积网络模块，能够有效去除伪影和噪声。然后通过 10 个自适应残差卷积模块，自适应残差卷积模块通过改进残差模块的卷积模块为可变形卷积，来实现自适应的地形特征提取。在每个特征提取模块中使用跃连接层来进行信息传递，防止梯度消失和过度拟合的问题。最后用一个亚像素卷积层来提高图像分辨率，达到上采样的目的，输出高分辨率 DEM。

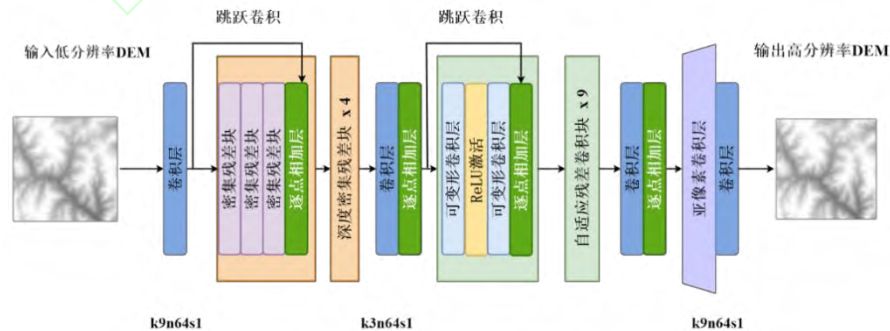


图 4 融合自适应卷积的生成器网络结构

Fig.4 Generator Network Structure Integrating Adaptive Convolution

## 1.4 DEM 高分辨率重建模型的判别器框架

DEM 的纹理特征往往是连续且多样的，为了进一步扩大判别器的感知范围，提高特征提取能力和稳定性，减少重建结果的瑕疵伪痕，本文参考 A-ESRGAN<sup>[21]</sup>模型的判别器，使用的注意力机制门模块来扩大感受野，捕获语义上下文信息。在标准 CNN 架构中的特征下采样，可以关注粗空间网格级别上关系特征，但对形状可变性较大的小物体很难减少假性正确预测。为了提高精度，可以通过一个整合注意模块(AB, Attention Block)来实现，与多级 CNN 中的定位模型不同，整合注意模块能够使用较少模型和少量额外的模型参数进行训练，不需要在网络之间裁剪兴趣区域，它能逐渐抑制不相关背景区域中的特征响应。

拼接模块 (CB)<sup>[21]</sup>将整合注意模块和前一步 U-Net 的输出作为输入，通过双线性插值对 U-Net 信息处理部分进行 2 倍特征下采样，然后通过普归一化的操作来增强 GAN 在训练过程中的稳定性，最后将 U-Net 部分与 AB 块信息进行拼接输出。

如图 5 所示，判别器的结构采用是一个标准的 U-Net 的框架，由一个下采样编码模块和一个上采样解码模块以及三个注意力机制 AB 块组成。在下采样编码模块中在网络的编码部分，输入图像被渐进地滤波，并在每个尺度下以因子 2 进行线性插值下采样，进行三次下采样操作，每次采样都在 CB 模块操作执行之前，从粗尺度上提取的信息传递到 AB 门控，以消除跳跃连接中的不相关和有噪声的响应。然后进行对应的上采样解码，每个尺度下以因子 2 进行插值。

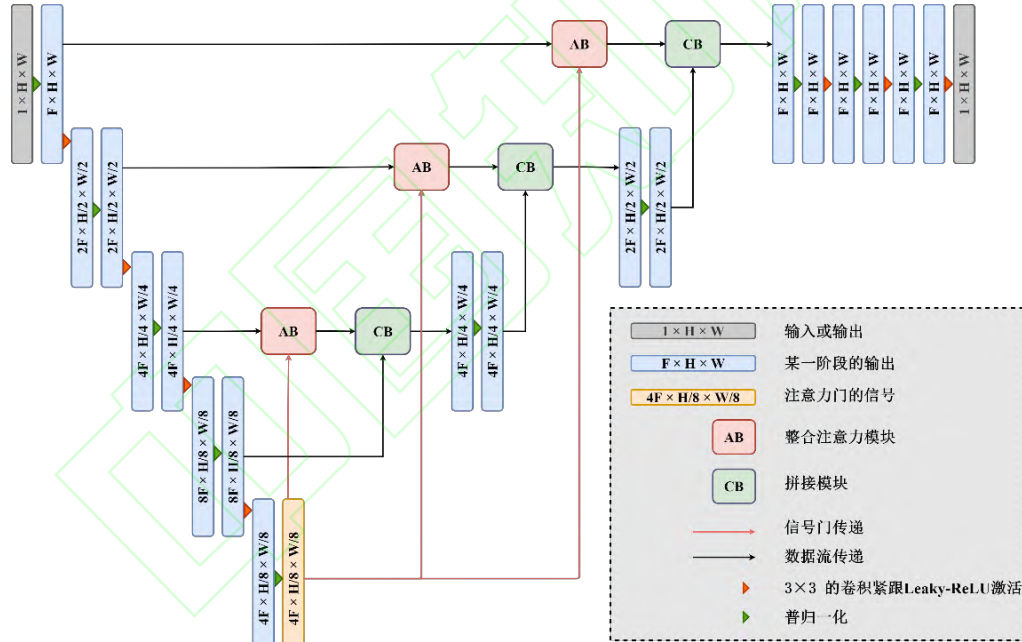


图 5 结合 U-Net 的判别器结构

Fig.5 Discriminator Structure Combined with U-Net

## 1.5 DEM 高分辨率重建模型的损失函数

损失函数是一种解决优化问题的学习准则，通过最小化损失函数求解来评估模型，来求取最优训练成果。而在生成对抗神经网络中，感知损失函数的确定直接关乎生成器网络的性能。常用的损失函数是均方根 MSE，本文参考 SRGAN 的损失函数，将损失函数分为两个部分：全局内容损失和对抗损失。

$$L_{total} = L_{content} + \alpha L_{Gen} \quad (1)$$

全局内容损失主要用来衡量生成器生成图像和原始图像之间的差异，常使用 (Mean

Absolute Error, MAE) 损失或者 (Mean Square Error, MSE) 损失。本文采用生成图像和目标图像的均方误差 (MSE 损失) 来优化全局地形精度, 全局内容损失包括两个部分, 生成图像和目标图像的均方误差和生成图像和目标图像特征图的均方误差, 计算如下:

$$L_{content} = L_{mse} + \beta L_{\phi mse} \quad (2)$$

$$L_{mse} = \frac{1}{N} \sum_i^N \left( I^{HR} - G_{\theta_G}(I^{LR}) \right)^2 \quad (3)$$

$$L_{\phi mse} = \frac{1}{N} \sum_i^N \left( \phi(I^{HR}) - \phi(G_{\theta_G}(I^{LR})) \right)^2 \quad (4)$$

其中,  $I^{LR}$  表示输入的低分辨率 DEM 图像,  $I^{HR}$  表示原始高分辨率图像,  $G_{\theta_G}$  表示生成器重建,  $\beta$  在训练中设定为 0.006,  $\phi$  代表对应 DEM 的特征图。

在训练阶段, 生成器的对抗损失如下:

$$L_{Gen} = \frac{1}{N} \sum_i^N \left| 1 - D(G(I^{LR})) \right| \quad (5)$$

其中  $N$  表示 DEM 单元的数量,  $I^{LR}$  代表低分辨率 DEM 输入,  $D$  表示判别器的鉴别结果,  $\alpha$  在本文训练中取  $10^{-3}$ 。

## 2 数据准备和评价指标

### 2.1 数据集介绍

为了验证本文提出的方法的有效性, 我们设计了两组 DEM 数据集来进行实验:

(1) 数据集 1: 12.5 米分辨率 DEM 数据选自中国四川省, 为 ALOS\_PALSAR\_12.5m 分辨率 DEM 数据, 拥有复杂的地形特征, 包含了山脊、沟谷、河流、盆地各种地形特征。然后对其进行了数据处理, 一共产生了两万张  $64 \times 64$  DEM 样本集。

(2) 数据集 2: 30 米分辨率 DEM 数据集选自美国地质调查局, 对 DEM 数据进行剪裁处理后, 一共产生了两万张  $64 \times 64$  DEM 样本集。

将实验数据集按数量分别为四组, A 组为一万张 30 米数据集, B 组为两万张 30 米数据集, C 组为一万张 12.5 米数据集, D 组为两万张 12.5 米数据集。DEM 数据存储格式为单通道输入和运算, 需要低分辨率 DEM 作为生成器输入, 需要对高分辨率 DEM 数据集进行下采样, 本文采用最近邻下采样方法, 将输入网络进行计算的数据集按照采样因子进行下采样, 得到低分辨率 DEM 作为生成器输入。本文的模型训练将 DEM 高程值归一化到  $[-1.0, 1.0]$  作为输入, 通过函数:

$$DEM_{i-n} = 2 \times \frac{DEM_i - H_{min}}{H_{max} - H_{min}} - 1 \quad (6)$$

其中  $DEM_{i-n}$  表示  $DEM_i$  的归一化版本,  $H_{max}$  和  $H_{min}$  分别表示  $DEM_i$  的最大和最小单元值。将归一化的低分辨率 DEM 作为网络模型的输入。通过模型训练后的结果通过 ASCII 格式的编码输出 DEM 图像, 然后转化为 Tiff 格式的图像进行可视化。

### 2.2 评价指标

为了对本文提出的方法进行定量评估, 对 DEM 超分辨率的重建精度评价指标采用均方根误差 (RMSE)、平均绝对误差 (MAE)、坡度误差 (Slope) 和坡向误差 (Aspect), 在



DEM 超分辨率重建任务中，计算公式如下：

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (h_i - \hat{h}_i)^2}{N}} \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |h_i - \hat{h}_i| \quad (8)$$

$$dx = [(h_{i-1,j+1} + 2h_{i,j+1} + h_{i+1,j+1}) - (h_{i-1,j-1} + 2h_{i,j-1} + h_{i+1,j-1})]/(8s) \quad (9)$$

$$dy = [(h_{i+1,j-1} + 2h_{i+1,j} + h_{i+1,j+1}) - (h_{i-1,j-1} + 2h_{i-1,j} + h_{i-1,j+1})]/(8s) \quad (10)$$

$$Slope_{ij} = \arctan \sqrt{dx^2 + dy^2} \quad (11)$$

其中  $\hat{h}_i$  和  $h_i$  分别表示真实高分辨率 DEM 和生成的高分辨率 DEM。 $h_{i,j}$  表示在位置 (i, j) 处的高程值，s 表示 DEM 的分辨率。在对 DEM 进行重建后通过计算其重建后的 RMSE、MAE、Slope 和 Aspect 的均值来评价模型方法的效果。

### 3 实验

#### 3.1 实验参数

为了探究本文提出的模型方法的可行性，本文将传统插值方法双三次插值、生成对抗超分辨率方法 (SRGAN、SwiftSRGAN)<sup>[22]</sup>、未优化判别器的方法 (SRGAN(DCG)) 以及本文提出的结合自适应卷积和融合 U-Net 生成对抗超分辨率重建方法 (SRDCGAN) 的重建效果进行对比。

本文的实验先对模型进行预训练，来提升模型训练的效率，预训练使用的是模型的生成器对数据集进行单独的训练，按照批量大小设置为 16，历元设置为 2，对模型进行预训练。损失采用全局内容损失：均方误差 (MSE 损失)  $L_{mse}$  计算如下：

$$L_{mse} = \frac{1}{N} \sum_i (h_i - \hat{h}_i)^2 \quad (12)$$

然后按照生成对抗网络模型的训练模式进行 100 次历元的训练，得到最终的训练结果。

在训练和测试中，这些网络都是在基于 Pytorch 框架实现的。在训练硬件方面，CPU 是 Intel(R) Core(TM) i9-11900K，GPU 是 NVIDIA GeForce GTX 3080 Ti 的配置。训练过程开始时，使用常用的网络优化器 Adam 对每次更新进行优化，预训练学习率  $10^{-2}$ ，训练学习率设置为  $10^{-6}$ ，批量大小设置为 16，历元设置为 100。

#### 3.2 对比实验

实验选取重建因子为 4 对分辨率为 30 米和 12.5 米分辨率的 DEM 数据集进行重建训练，分别用数据集 A、B、C、D 基于双三次插值 (Bicubic)、生成对抗超分辨率方法 (SRGAN、SwiftSRGAN) 以及本文提出的改进的生成对抗超分辨率重建方法 (SRDCGAN) 重建出从分辨率 120 米到 30 米和 50 米到 12.5 米的 DEM。

首先，本文提出的方法 SRDCGAN 相较于 SRGAN 在模型收敛速度方面占据了明显的优势。图 6 是基于四种数据集下基于 SRGAN 和 D-SRAN 方法，超分辨率重建 DEM 的训

训练生成对抗损失的可视化曲线图。可以明显看出 SRDCGAN 收敛速度更快，而 SRGAN 的对抗损失在训练过程中出现震荡，甚至还出现了需要再次降低学习率训练的情况，说明 SRGAN 模型训练整体不稳定。SRDCGAN 方法使得模型训练速度更快，训练更稳定。

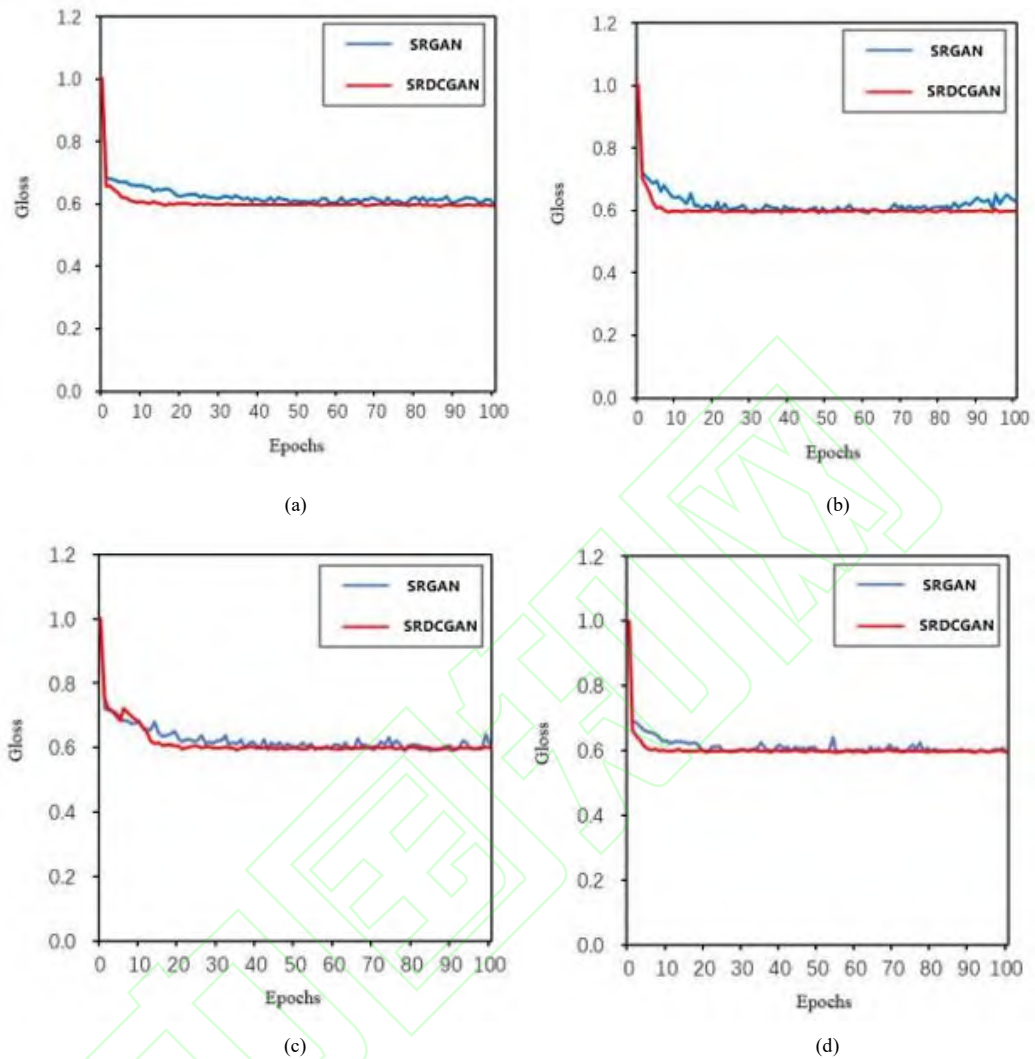


图 6 训练损失曲线

Fig.6 Training loss curves

如表 1 中所示，分别统计了测试数据集中 DEM 的重建精度评估指标，从 RMSE、MAE 和 Slope 指标来看，本文提出的方法相较于传统方法和 SRGAN 方法来说，对 DEM 的超分辨率重建效果有显著的提升，RMSE 均值下降了 0.3%-12.6%、MAE 均值下降了 3.2%-14.5%、Slope 均值下降了 1.9%-18.3%，Aspect 均值下降了 2.7%-12.0%。虽然坡向指标在 30 米数据集中传统方法更好，但相较于 SRGAN 本文的方法有明显提升。在判别器的消融实验中，SRDCGAN 亦取得相对较好的效果。

总的来说，从各项评估指标来看，深度学习方法相较于传统插值方法更稳定，重建的效果更好，SRDCGAN 在四种方法中能取得相对更好的重建结果。说明本文提出的方法在重建精度方法具有很好的可行性。

表 1 测试结果评估

Table 1 Evaluation of Test Results

数据集	方法	RMSE	MAE	Slope	Aspect
A	Bicubic	0.811	0.475	2.099	1.542
	SRGAN	0.849	0.548	1.951	1.619
	Swift-SRGAN	0.979	0.695	2.249	1.736
	SRGAN(DCG)	0.735	0.440	1.903	1.550
	<b>SRDCGAN</b>	<b>0.785</b>	<b>0.485</b>	<b>1.896</b>	<b>1.564</b>
B	Bicubic	2.289	1.33	4.083	1.505
	SRGAN	2.289	1.507	4.089	1.571
	Swift-SRGAN	2.549	1.882	3.713	1.532
	SRGAN(DCG)	2.195	1.400	4.065	1.556
	<b>SRDCGAN</b>	<b>2.144</b>	<b>1.348</b>	<b>4.010</b>	<b>1.529</b>
C	Bicubic	1.252	0.727	2.62	1.400
	SRGAN	1.025	0.692	2.649	1.384
	Swift-SRGAN	1.042	0.721	2.172	1.263
	SRGAN(DCG)	1.071	0.694	2.285	1.314
	<b>SRDCGAN</b>	<b>1.022</b>	<b>0.670</b>	<b>2.307</b>	<b>1.313</b>
D	Bicubic	1.693	0.920	3.186	1.281
	SRGAN	1.474	0.944	3.143	0.695
	Swift-SRGAN	1.308	0.858	2.460	1.194
	SRGAN(DCG)	1.285	0.803	2.560	1.215
	<b>SRDCGAN</b>	<b>1.289</b>	<b>0.807</b>	<b>2.569</b>	<b>1.212</b>

如图 7 所示，展示了 A 和 B 组数据集的典型地形重建结果。由于下采样因子为 4，DEM 丢失了大量的地形信息，所以在重建复杂地形时难以重建出完全符合实际的地形特征。从地形特征上来看，双三次插值方法边缘平滑，地形特征恢复不全，SRGAN 虽然恢复了更多的地形，但图像四周存在大量噪声和伪影。例如 B 组①组和③组 DEM 结果中，红框区域能够直观看出双三次插值方法的重建结果边缘平滑，地形特征丢失或与实际地形不符，重建结果边缘存在伪影。从 A 组数据集第②和③组的结果来看，RMSE 相较于双三次有了显著的提高，但是重建的结果存在明显不符合地形特征的伪影和噪声，图像四周存在大量的噪声。SwiftSRGAN 方法存在大量的锯齿和伪影，可以从可视化结果中看出此方法更适用于纹理特征极其明显的情况。而本文提出的 SRDCGAN 模型重建出了更多 DEM 地形特征，也降低了伪影和噪声的产生。




图 7 30 米分辨率数据集测试重建结果可视化

Fig.7 Visualization of Reconstruction Results from 30m Resolution Dataset

如图 9 所示，展示了 C 和 D 组数据集的典型地形重建结果。由于数据集的分辨率本身较高，所以地形特征的提取都有较好的效果。从重建精度评估指标 RMSE 来看，C 和 D 组 SRGAN 方法重建 RMSE 值都很高，因为原始较高的分辨率数据，SRGAN 方法重建造成的伪影和噪声对 DEM 的精度影响较大。从 C、D 组实验结果可以看出，第②组 DEM 的 SRGAN 方法实验结果 RMSE 都很高，由于地形平坦，而 SRGAN 想要保留纹理特征，反而产生了大量的伪影和噪声，导致 RMSE 值较大，SwiftSRGAN 方法稳定性较差，并且重建结果存在大量的锯齿和伪影。而本文提出的 SRDCGAN 不仅减少了伪影和噪声，RMSE 也是相较于双三次插值方法和 SRGAN 方法最低，有最好的重建精度。

对重建结果进行了河网分析，可以看出 SRDCGAN 方法对河流特征的保留效果相对更好，如图 8 所示，从①、②、③和④组数据可以明显看出，使用 SRDCGAN 方法的河网分析结果图河流网络更连续、完整，没有明显的断裂或缺失。能够较准确地反映出研究区域的水系分布情况。




图 8 数据集测试重建结果河网分析

Fig.8 Data Set Test Reconstruction Results River Network Analysis

无论是在复杂或是简单的地形中，本文提出的 SRDCGAN 方法都能够取得最好的重建效果，能够在保留地形特征的情况下，降低伪影和噪声的产生，得到了较高精度结果。说明本文提出的对生成器和判别器中各个模块的改进，有效的改善了 SRGAN 存在伪影和噪声以及模型不稳定的问题，SRDCGAN 能够在 DEM 超分辨率重建任务中取得良好的效果。




图9 12.5米分辨率数据集测试重建结果可视化

Fig.9 Visualization of Reconstruction Results from 12.5m Resolution Dataset

## 4 结语

本文提出了融合自适应卷积和 U-Net 的生成对抗神经网络超分辨率重建模型。此模型生成器特征提取模块采用深度残差密集模块和自适应残差卷积模块，深度残差密集模块减少了 SRGAN 重建所产生的伪影和噪声，增加感受野的同时加强了模型特征提取的能力。自适应卷积模块通过将可变形卷积引入到残差网络模块中，使网络模型能够自适应提取特征信息，负责学习更多的地形特征。判别器融合了注意机制的 U-Net 结构，U-Net 具有良好的性能和对 GPU 内存的高效使用，注意机制捕获足够大的感受野，捕获语义上下文信息，提高 DEM 的重建精度和学习效率。提出的模型有效的改善 DEM 重建边缘平滑，重建存在伪影和噪声以及缺少部分地形特征的问题。通过比较不同方法在不同分辨率数据集下重建高分辨率 DEM 的精度，提出的方法相较于传统的插值重建方法和 SRGAN 方法取得了更良好的效果，得到的结果地形纹理特征更明显，高程 RMSE、MAE 和坡度、坡向有明显的提升。结果表明，SRDCGAN 方法能够为从某个区域的高分辨率和低分辨率 DEM 数据建立映射模型，其他区域的高分辨率 DEM 可以使用具有低分辨率 DEM 的映射模型重建 SRDCGAN 有望在使用高分辨率 DEM 的地质应用中实现高实用价值。

## 参考文献

- [1] Gao Yuan, Zhu Yanan, Chen Zhuanfa. Weighted Radial Basis Function Interpolation for High-

- Precision DEM Modeling[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48, 1373-1379.(高原, 朱娅男, 陈传法. 高精度 DEM 建模的加权径向基函数插值方法. 武汉大学学报 (信息科学版), 48, 2023,1373-1379)
- [2] Arai, K., Terayama, Y., Nakamura, K. A comparative study on interpolation methods for digital elevation model[C]. In, *Proceedings of IGARSS '93 - IEEE International Geoscience and Remote Sensing Symposium*, 1993, 1975-1977
- [3] Yonglong, X. Theoretical Applications of Digital Elevation Models and Their Development (Continued)[J]. *Journal of Geomatics*, 1986, 38-44(徐永龙. 数字高程模型的理论应用及其发展(续)[J]. 武测科技, 1986, 38-44)
- [4] Yaoge, W., Xin, W., Changqing, Z. Bilinear Interpolation Rule Grid Based DEM Topographic Error Modeling[J]. *Journal of Geomatics Science and Technology*, 2007, 419-421.(王耀革, 王鑫, 朱长青. 基于双线性内插规则网格 DEM 地形误差模型[J]. 测绘科学技术学报. 2007, 419-421.)
- [5] Lee, S., Wolberg, G., Shin, S.Y. Scattered data interpolation with multilevel B-splines[C]. *IEEE Transactions on Visualization and Computer Graphics*, 1997,3, 228-244.
- [6] Xiong, L. Double Cubic COONS Surfaces for Super-resolution of Sequence Images.[D] *Dalian University of Technology*, 2005. (刘雄. 双三次 COONS 曲面在序列图像超分辨率中的应用[D]. 辽宁: 大连理工大学, 2005.)
- [7] Xu, C., Huiming, Z. Research on Spatial Interpolation Method Based on Pan-coherent Kriging Method[J]. *Computer Knowledge and Technology*, 2015, 11, 220-222. (程勳, 张明会. 基于泛协克里格法的空间插值方法研究[J]. 电脑知识与技术, 2015, 11 :220-222.)
- [8] Hua Weihua, Guo Danyang, Liu Xiuguo at all. Unified Correction and Connection Method of Stratigraphic Sequence with Complex Inversion [J]. *Journal of Earth Science*, 2023, 48: 1532-1542.(花卫华, 郭丹阳, 刘修国等. 含复杂倒转的地层层序统一修正与连接方法. *地球科学*, 2023, 48, 1532-1542)
- [9] Hua Weihua, Zeng Xinling, Guo Danyang at all. 3D Geological Modeling Method Based on Tectonic Restoration Theory [J]. *Journal of Earth Science*, 2024, 49, 1411-1420. (花卫华, 曾新灵, 郭丹阳等. 基于构造恢复理论的含复杂断层三维地质建模方法. *地球科学*, 2024, 49, 1411-1420)
- [10] Dong, C., Loy, C.C., He, K. at all. Learning a Deep Convolutional Network for Image Super-Resolution[C]. In D. Fleet, T. Pajdla, B. Schiele, & T. Tuytelaars (Eds.), *Computer Vision – ECCV 2014* 2014, 184-199.
- [11] CHEN Hang, LUO Bin. Multi-angle Remote Sensing Images Super-Resolution Reconstruction Using Dynamic Upsampling Filter Deep Network[J]. *Geomatics and Information Science of Wuhan University*, 2021, 46(11): 1716-1726.(陈行, 罗斌. 利用动态上采样滤波深度网络进行多角度遥感影像超分辨率重建. 武汉大学学报 (信息科学版), 2021, 46, 1716-1726.)
- [12] Ledig, C., Theis, L., Huszár, F. at all. Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network[C]. In, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2017*, 105-114.
- [13] Demiray, B.Z., Sit, M., Demir, I. D-SRGAN: DEM Super-Resolution with Generative Adversarial Networks[J]. *SN Computer Science*, 2021, 2, 48
- [14] Zhou, A., Chen, Y., Wilson, J.P. at all. 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
- [15] 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
- [16] Zhang, Y., Li, K., Li, K. at all. Image Super-Resolution Using Very Deep Residual Channel Attention Networks[C]. In V. Ferrari, M. Hebert, C. Sminchisescu, & Y. Weiss (Eds.), *Computer Vision – ECCV 2018* (pp. 294-310). Cham: Springer International Publishing
- [17] Zhu, D., Cheng, X., Zhang, F. at all. Spatial interpolation using conditional generative adversarial neural networks[J]. *International Journal of Geographical Information Science*,2020, 34, 735-758
- [18] Wang, X., Yu, K., Wu, S. at all. ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks[C]. In L. Leal-Taixé, & S. Roth (Eds.), *Computer Vision – ECCV 2018 Workshops 2019*, (pp. 63-79). Cham: Springer International Publishing
- [19] Dai, J., Qi, H., Xiong, Y. at all. Deformable Convolutional Networks[C]. In, *2017 IEEE International Conference on Computer Vision (ICCV)* ,2017, 764-773
- [20] Su, H., Jampani, V., Sun, D. at all. Pixel-Adaptive Convolutional Neural Networks. In, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* ,2019,11158-11167
- [21] Wei, Z., Huang, Y., Chen, Y. at all. A-ESRGAN: Training Real-World Blind Super-Resolution with Attention U-Net Discriminators[C]. *Trends in Artificial Intelligence: 20th Pacific Rim International Conference on Artificial Intelligence*, Jakarta, Indonesia, 2023.
- [22] Krishnan, Koushik Sivarama at all. SwiftSRGAN - Rethinking Super-Resolution for Efficient and Real-time Inference[J]. *Cornell University*,2021, 46–51.

#### 网络首发:

标题: 基于自适应生成对抗网络的 DEM 超分辨率重建方法

作者: 侯旭娟, 邓筱瞳, 花卫华, 殷婉婷, 李鹏, 齐春雨

收稿日期: 2024-11-18

DOI:10.13203/j.whugis20240186

#### 引用格式:

侯旭娟, 邓筱瞳, 花卫华, 等. 基于自适应生成对抗网络的 DEM 超分辨率重建方法[J]. *武汉大学学报 (信息科学版)*, 2024, DOI:10.13203/J.whugis20240186 (HOU Xujuan, DENG Xiaotong, HUA Weihua, et al. DEM Super-resolution Reconstruction Method Based on Adaptive Generative Adversarial Network[J]. *Geomatics and Information Science of Wuhan University*, 2024, DOI:10.13203/J.whugis20240186)

网络首发文章内容和格式与正式出版会有细微差别, 请以正式出版文件为准!

#### 您感兴趣的其他相关论文:

##### 数据融合视角下的遥感参量空间降尺度

景映红, 沈焕锋, 李星华, 吴金橄, 邱中航

武汉大学学报(信息科学版), 2024, 49(2): 175-189.

<http://ch.whu.edu.cn/article/doi/10.13203/j.whugis20220549>

##### 基于深度置信网络的多源 DEM 点面融合模型

岳林蔚, 沈焕锋, 袁强强, 刘修国

武汉大学学报(信息科学版), 2021, 46(7): 1090-1097.



<http://ch.whu.edu.cn/article/doi/10.13203/j.whugis20190238>

**利用卷积神经网络进行“问题地图”智能检测**

任加新, 刘万增, 李志林, 李然, 翟曦

武汉大学学报(信息科学版), 2021, 46(4): 570-577.

<http://ch.whu.edu.cn/article/doi/10.13203/j.whugis20190259>

