

融合残差网络和纹理转移模型的单幅遥感图像超分辨率重建方法

陶钰皎

(青海交通职业技术学院, 西宁 810003)

摘要: 遥感图像极易受到环境和天气因素的影响, 分辨率降低, 为提高单幅遥感图像细节信息的提取质量, 在融合残差网络和纹理转移模型的支持下, 优化设计单幅遥感图像超分辨率重建方法; 考虑遥感图像的退化现象, 按照遥感成像原理, 获取低分辨率的单幅遥感图像; 通过去雾、平滑滤波、颜色空间转换等步骤, 实现对初始遥感图像的赋值; 融合残差网络和纹理转移模型, 进行单幅遥感图像纹理特征标记, 确定图像重建规律, 经过图像细节损失补偿, 得出单幅遥感图像的超分辨率重建结果; 以不同尺寸的遥感图像作为研究目标, 实验结果表明, 所提方法得出重建图像峰值信噪比提高约 204, 重建图像分辨率始终为 1 080 dpi, 同时图像重建任务的时间开销得到明显降低。

关键词: 残差网络; 纹理转移模型; 遥感图像; 图像重建; 超分辨率

Super-resolution Reconstruction Method for Single Remote Sensing Image Based on Residual Network and Texture Transfer Model

TAO Yujiao

(Qinghai Communication Technical College, Xining 810003, China)

Abstract: Remote sensing images are highly susceptible to environmental and weather factors, resulting in reduced resolution. In order to improve the quality of extracting the detailed information from a single remote sensing image, a super-resolution reconstruction method for a single remote sensing image is optimized and designed with the support of fusion residual networks and texture transfer models. By considering the degradation phenomenon of remote sensing images, the single low resolution remote sensing image is obtained according to the principle of remote sensing imaging. The assignment of initial remote sensing images is achieved through the steps of defogging, smoothing filtering, and color space conversion. By integrating the residual networks and texture transfer models, the single remote sensing image texture feature labeling is performed to determine the image reconstruction pattern. After the image detailed loss is compensated, the super-resolution reconstruction results of the single remote sensing image are obtained. The remote sensing images of different sizes are taken as a research objective, experimental results show that the proposed method improves the peak signal-to-noise ratio of the reconstructed image by about 204, and the resolution of the reconstructed image is always 1 080 dpi. Also, it significantly reduces the time cost of the image reconstruction.

Keywords: residual network; texture transfer model; remote sensing images; image reconstruction; super resolution

0 引言

遥感图像是通过使用各种传感器仪器收集远处目标辐射和反射的电磁波信息而生成的图像, 主要可分为两类: 航空图像和卫星图像。在确定工程地质现象的一系列行之有效的方法中, 遥感图像可以降低实地工作量, 提高地质勘探的工作效率和质量, 因此在工程地质测绘、土地管理、植被管理等工作中具有重要的应用价值。遥感图像大多以连续影像形式进行采集, 但在实际应用中, 受衍射、大气环流干扰、欠采样、传感器相对位移、噪声等多种因素的影响, 图像存在混叠、模糊和空间分辨率下降等问题。

单幅遥感图像的分辨率直接决定了遥感图像中有效信息的提取效果, 为了提高遥感图像的利用率, 提出单幅遥感图像超分辨率重建方法。现阶段发展较为成熟的图像重

建方法包括: 李岚等人^[1]在 ResNet 网络基础上, 提出一种锯齿型空穴卷积算法, 扩展网络感知野, 减少“网络化”现象, 同时加入跳连线, 实现图像特征向深层传输, 再经过最后一层卷积层, 获得与原图等尺寸的残差图像, 将 LR 影像和剩余影像进行线性融合, 得到超分辨率重建结果。董本志等人^[2]在二维离散小波变换所构建的小波域中, 采用稠密连通、残差连通等方法, 充分提取图像中各频段的信息, 将融合后的图像特征输入亚像素卷积层处, 得到高分辨图像的子带状图像, 由二维离散小波反演, 得到高分辨图像重建结果。贺温磊等人^[3]通过去除产生网络中的贝叶斯网络层, 并通过对剩余块进行联结, 提高网络的模型容量, 减少运算复杂度, 提高网络训练的稳定性, 采用迁移学习的深度学习方法以提高深度模型的训练效率, 从而缓解遥感数据匮乏的问题。

收稿日期: 2023-09-07; 修回日期: 2023-10-19。

作者简介: 陶钰皎(1984-), 女, 大学本科, 讲师。

引用格式: 陶钰皎. 融合残差网络和纹理转移模型的单幅遥感图像超分辨率重建方法[J]. 计算机测量与控制, 2024, 32(10): 187-193.

残差网络是卷积神经网络中的概念，它通过引入一种“跳变”结构，使其仅需要学习到输入与输出的残差信息，具有易于优化和通过增大较大深度而改善精度的特性。通过对其内部剩余块进行跳连，解决了由于深度增大而导致的梯度丢失的问题。遥感图像有着丰富的纹理信息，纹理特征是遥感图像的基本特征之一。纹理转移模型是模拟图像中纹理特征移动规律的模型。利用融合残差网络和纹理转移模型对单幅遥感图像超分辨率重建方法进行优化设计，以期能够提升遥感图像的重建质量。

1 单幅遥感图像超分辨率重建方法设计

1.1 遥感图像退化与初始化分析

通过遥感成像技术，可以获取大量的土地利用和土地覆盖数据，为土地资源的合理利用和保护提供数据支持。遥感技术可以大面积快速地获取各种高分辨率和高精度地球表面数据，具有广阔的视域和快速的数据获取能力。利用遥感成像技术采集初始遥感图像，其算式为：

$$\begin{bmatrix} x \\ y \end{bmatrix} = \kappa_{scale} \mathbf{A}_{revolve} \mathbf{A}_{gesture} \begin{bmatrix} x_{in\ kind} \\ y_{in\ kind} \\ z_{in\ kind} \end{bmatrix} \cdot \theta \quad (1)$$

式中， κ_{scale} 为遥感成像比例系数， $\mathbf{A}_{revolve}$ 和 $\mathbf{A}_{gesture}$ 为遥感成像设备的旋转矩阵和姿态矩阵， θ 为成像角， $(x_{in\ kind}, y_{in\ kind}, z_{in\ kind})$ 为遥感成像目标对应的实物对象位置坐标^[4]。由于遥感成像技术的数据量大、种类多、分辨率和波段各不相同，且受采集设备硬件缺陷、环境条件、传输介质和存储条件等不可控因素的影响，导致最终接收的遥感图像采集结果是退化后、质量降低的图像，考虑到光照条件、云量、风速和气候等因素对图像质量的影响，为保证图像重建获取的初始图像与遥感图像实际的采集与接收结果一致，需要对初始采集的图像进行退化模拟，退化模拟流程如图 1 所示。

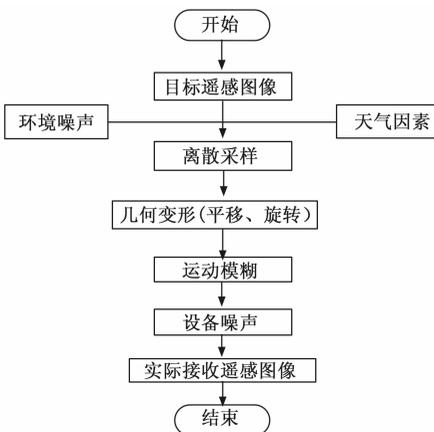


图 1 遥感图像退化模拟流程图

了解和处理遥感图像退化因素可以减少数据丢失和失真，将遥感图像初始化获取结果表示为：

$$I_{LOW}(x, y) = \kappa_{down-sampling} \cdot \delta \cdot \xi \begin{bmatrix} x \\ y \end{bmatrix} + \psi \quad (2)$$

式中， $\kappa_{down-sampling}$ 为初始遥感图像的下采样系数， δ 和 ξ 分别为模糊算子和几何形变量， ψ 为图像采集与传输过程中引入的

附加噪声^[5]。不同地表材质和植被覆盖对光的反射具有差异性，引起不均匀的图像亮度，同时不同视角下观测到的地物形态和信息可能存在差异，导致图像的几何变形，将公式(1)的初始成像结果代入到公式(2)中，对受大气干扰的图像进行校正，恢复真实地表反射率，并进行精确配准，消除几何畸变，即可得出单幅低分辨率遥感图像的初始化获取结果，提供高重复周期和高时间分辨率的数据。

1.2 单幅低分辨率遥感图像赋值

初始化获取的单幅低分辨率遥感图像可能存在雾气遮挡、噪声点等干扰因素，影响重建结果，为此需要对其进行赋值，赋值步骤包括图像去雾、平滑滤波等^[6]。在图像去雾处理之前，通常估计最不透明、最模糊的像素，分析遥感图像成像环境中的大气光照程度。在遥感图像中，暗原色的值可以用来估计大气光照。当大气光已知时，在遥感图像区域中，透射率被视为常数，由此从初始遥感图像中随机选择 3 个颜色通道的极值加以分析，得到初始遥感图像去雾处理的结果^[7]。

低分辨率遥感图像的分辨率较低，在采样过程中会丢失一部分原始图像的信息，无法准确细致地表现图像内容，边缘信息也会模糊不清，丧失了原始图像的锐利度，导致图像细节不够清晰，且数据量相对较小，占用存储空间较少，对此采用一个 $p \times q$ 的窗口又称模板进行图像滤波，图像滤波的原理其实就是在初始遥感图像中，将模板一步一步地移到图像中，让遥感图像中的某一像素点与模板中心一致，并根据模板的具体内容，对图像中的每一点作出回应。图像平滑滤波过程可以量化表示为：

$$I_{filtering}[I_{LOW}(x, y)] = \sum_{p=-a}^a \sum_{q=-b}^b I(x+p, y+q) \quad (3)$$

式中，参数 a 和 b 的计算公式如下：

$$\begin{cases} a = \frac{p-1}{2} \\ b = \frac{q-1}{2} \end{cases} \quad (4)$$

将公式(4)的计算结果代入公式(3)中，得出初始单幅低分辨率遥感图像的平滑滤波处理结果^[8]。遥感图像中颜色是重要组成部分之一，为满足不同用途的需求，需要对初始遥感图像的颜色空间进行转换，RGB 颜色空间到 HSB 颜色空间的转换过程如下：

$$H = \begin{cases} 0^\circ & V_{max} = V_{min} \\ 60^\circ \times \frac{G-B}{V_{max}-V_{min}} + 0^\circ & V_{max} = R \quad G \geq B \\ 60^\circ \times \frac{G-B}{V_{max}-V_{min}} + 360^\circ & V_{max} = R \quad G < B \\ 60^\circ \times \frac{G-R}{V_{max}-V_{min}} + 120^\circ & V_{max} = G \\ 60^\circ \times \frac{R-G}{V_{max}-V_{min}} + 240^\circ & V_{max} = B \end{cases} \quad (5)$$

$$S = \begin{cases} 0 & V_{max} = 0 \\ \frac{V_{max}-V_{min}}{V_{max}} = 1 - \frac{V_{min}}{V_{max}} & V_{max} \neq 0 \end{cases}$$

式中, R 、 G 和 B 分别为 RGB 颜色空间中的红、绿和蓝色颜色分量, H 、 S 分别为遥感图像中的色调和纯度分量, V_{\min} 和 V_{\max} 为明暗度的最大值和最小值^[9]。按照上述方式对遥感图像中的所有像素点进行处理, 在已知数据点之间推测新数据点的值, 完成对低分辨率遥感图像的赋值, 保证在大范围监测和图像获取方面具有优势, 提供全局视角和广阔的信息。

1.3 单幅遥感图像纹理特征标记

低分辨率图像的细节信息较少, 物体边缘和细微特征的表达不如高分辨率图像清晰, 存在一定的空间模糊, 由此以采集并赋值完成的遥感图像作为研究对象, 通过特征提取与演化得出图像特征的分布与变化规律, 分析图像重建规律。

单幅遥感图像中的不同类别的纹理特征具有一定的差异性, 可以用于区分不同地物或目标, 纹理特征通常基于局部像素的空间关系构建, 能够捕捉到图像中的非局部性信息。而不同的纹理特征提取方法具有不同的参数设置, 需要对参数进行合理调整以获取更准确的特征表示, 以此构建用来提取图像特征的残差网络, 如图 2 所示。

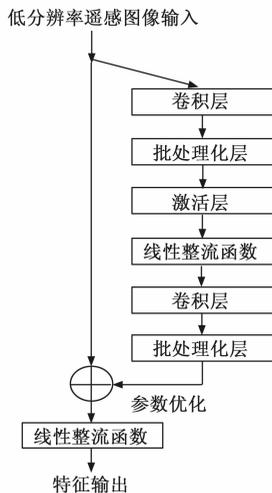


图 2 残差网络结构图

1) 定义卷积层、批处理化层等: 选择适当卷积层构建残差网络。常用的结构包括 ResNet、ResNeXt、DenseNet 等。这些结构一般由多个层组成, 包括卷积层、批量归一化层、激活函数等。根据任务需求和实际情况, 可以调整网络深度和宽度。

2) 设计残差模块: 在残差网络中, 主要使用残差模块来构建网络层。残差模块由两个分支组成: 主分支和跳跃连接 (或称为捷径连接)。主分支用于学习输入数据的非线性变换, 而跳跃连接直接将输入数据添加到输出数据中, 用于传播原始信息。常使用的残差模块包括基本残差单元或瓶颈残差单元。

3) 加入批量归一化和激活函数: 对每个残差模块进行批量归一化操作, 以加速收敛, 并在残差模块之后应用激

活函数, 如 ReLU (修正线性单元)。

4) 网络连接和层堆叠: 通过将残差模块连接起来, 建立整个网络。通常采用串联 (或串级) 方式连接残差模块, 形成一个多层的残差网络。

5) 全局平均池化和分类层: 对最后一个残差模块的输出进行全局平均池化, 将高维特征图转换为一维特征向量。然后, 将该特征向量输入到一个全连接层, 最后使用 softmax 分类器进行图像分类或其他任务。

6) 参数优化: 使用训练数据对构建好的残差网络进行训练, 以学习特征表示和参数权重。在训练过程中, 利用反向传播和优化方法 (如随机梯度下降) 对网络参数进行优化。

7) 网络评估和应用: 对比线性整流函数, 使用测试数据对已训练好的网络进行评估和验证。

利用残差网络, 提取初始遥感图像中的纹理特征、颜色特征、边缘特征等, 以残差网络输出的图像特征提取结果为初始值, 利用纹理转移模型得出图像纹理特征的变化规律, 得出图像重建规律^[10-11]。保证了神经网络在下一层的映射网络中所含的特征信息要比上一层的网络中所含的特征信息要多, 随着网络的层数的加深, 特征映射层所含的特征信息会逐渐减少的问题^[12]。包括以下两个主要原因:

空间分辨率下降: 每一层的卷积操作都会导致特征映射的空间分辨率下降。这意味着每个特征映射包含的空间信息较少。通过下采样 (例如通过 2×2 的平均池化) 或步长较大的卷积, 空间分辨率可以进一步降低。

感受野 (Receptive Field) 增大: 每一层的卷积操作都会使神经元的感受野增大。感受野是神经元可以接收到的输入区域。感受野的增大使得神经元能够“看到”更多的输入空间, 从而捕获更大范围的特征。但是, 这也意味着单个神经元所包含的特征信息会减少。

然而, 需要注意的是, 虽然随着网络的层数的加深, 特征映射层所含的特征信息会逐渐减少, 但这并不意味着信息的质量或数量会减少。反而, 由于网络深度增加, 能够提取到的特征的复杂性会增加。

上一残差块的输出经过特征提取单元中的卷积层和激活层为:

$$Z = f_{\max}(\zeta, 0) \quad (6)$$

式中, ζ 为残差密集块, $f_{\max}(\cdot)$ 为最大值求解函数^[13]。为使特征信息得到最大程度地利用, 并维持梯度存在的状态, 当特征图通过剩余块时, 剩余块的输出层与前一个剩余块的输出相结合, 从而形成局部剩余学习, 构建的残差网络由多个残差块组成, 残差块可以量化表示为:

$$k_{i+1} = Zk_i + h(k_i, W_i) \quad (7)$$

式中, 变量 k_i 为网络的直接映射, $h(k_i, W_i)$ 为残差部分。如果网络中存在更深层的 L 层, 则它与 L 层之间的关系可进一步表达为:

$$k_L = \sum_{i=1}^{L-1} k_{i+1} + \sum_{i=1}^{L-1} h(k_i, W_i) \quad (8)$$

式中, $h(\cdot)$ 表示残差网络的激活函数。可以看出残差网络在整个训练过程中, 因为其 L 层是由比它浅的任意 I 层的残差网络之和得到的, 并且 L 层的梯度可以传递到任何比它浅的 I 层上面, 所以残差网络不会存在梯度消失的问题, 强化了网络层与层之间的信息^[14]。残差网络是利用一种捷径连接, 在一层或更多层之间进行跳转, 从而使网络的层次结构发生变化, 综合考虑残差块的工作原理, 将残差网络的输出表示为:

$$y = \{k_L[I(x, y)] + I(x, y)\} I_{\text{filtering}}[I_{\text{LOW}}(x, y)] \quad (9)$$

低分辨率图像由于其分辨率的限制, 通常在表达物体边缘和细微特征时不如高分辨率图像清晰。在遥感图像中, 低分辨率图像的空间模糊可能会导致丢失一些重要的细节信息。然而, 该残差网络中的连接方式没有增加新的网络层和多余的参数, 只利用少量的参数, 就能获得更多的高频信息, 并提高网络的收敛性。因此, 在重构模型中加入残差网络的结构, 可以有效地提取出更多的高频细节^[15]。在残差网络学习过程中, 使用梯度进行残差块权重更新, 更新过程可以描述为:

$$W_l = \frac{\partial h(k_l, W_l)}{\partial y} \quad (10)$$

在考虑残差网络的深层结构的情况下, 得出残差网络的综合权重更新结果, 并代入到残差网络的学习训练过程中, 最终网络输出结果即为遥感图像颜色的特征提取结果^[16]。颜色特征的具体提取分量包括颜色直方图和颜色矩, 颜色直方图特征的标记结果为:

$$\tau_{\text{Color-Histogram}} = \frac{f_{\max}(H, S) f_{\max}(R, G, B) W_{i n_g}}{n} \quad (11)$$

式中, n_g 和 n 分别表示灰度值为 g 的像素在整个单幅遥感图像中出现的次数以及遥感图像的总像素点数量。另外, 残差网络输出的遥感图像颜色矩特征分量的标记结果为:

$$\begin{cases} \tau_{\text{color moment}}(1) = \frac{1}{n} \sum_{j=1}^n r_{ij} \\ \tau_{\text{color moment}}(2) = \sqrt{\frac{1}{n} \sum_{j=1}^n [r_{ij} - \tau_{\text{color moment}}(1)]^2} \\ \tau_{\text{color moment}}(3) = \sqrt[3]{\frac{1}{n} \sum_{j=1}^n [r_{ij} - \tau_{\text{color moment}}(1)]^3} \end{cases} \quad (12)$$

式中, $\tau_{\text{color moment}}(1)$ 、 $\tau_{\text{color moment}}(2)$ 和 $\tau_{\text{color moment}}(3)$ 分别表示遥感图像颜色的一阶矩、二阶矩和三阶矩特征, r_{ij} 表示单幅遥感图像中第 j 个像素的第 i 个颜色分量^[17]。最终将公式 (11) 和公式 (12) 的标记结果进行融合处理, 融合过程如下:

$$\tau_{\text{color}} = \bar{\omega}_{\text{color1}} \tau_{\text{Color-Histogram}} + \bar{\omega}_{\text{color2}} \sum_{\gamma=1}^3 \tau_{\text{color moment}}(\gamma) \quad (13)$$

式中, $\bar{\omega}_{\text{color1}}$ 和 $\bar{\omega}_{\text{color2}}$ 分别为颜色特征向量的融合加权系数, 将公式 (10) 和公式 (11) 的特征标记结果代入到公式 (12) 中, 即可得出单幅遥感图像颜色特征的标记结果。在此基础上, 融合残差网络和纹理转移模型对单幅遥感图像的纹理特征进行标记, 图 3 表示的是融合残差网络和纹理转移模型的融合结构。

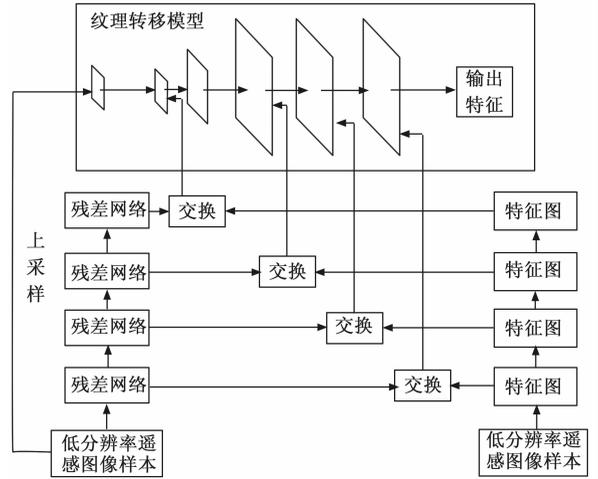


图 3 残差网络和纹理转移模型的融合结构

图 3 中, 在各种尺度的特征层中把多个交换的纹理特征图融合到一个基础的深度生成网络中。遥感图像对应的纹理转移模型可以表示为:

$$U(x) = \{\varphi_{\text{res}}[y_{l-1} \parallel I(x, y)] + \kappa_{\text{transfer}}\} \quad (14)$$

式中, κ_{transfer} 为图像纹理转移系数, φ_{res} 为残差块。由此得出单幅遥感图像纹理特征的标记结果为:

$$\tau_{\text{texture}} = \frac{\sum I(x, y) U(x - \sigma_x, y - \sigma_y)}{I(x, y)} \quad (15)$$

式中, σ_x 和 σ_y 分别为遥感图像中各个像素偏离量在水平和竖直方向上的分量^[18], 以此作为单幅遥感图像的重建规律。

1.4 超分辨率损失补偿

为了恢复初始图像细节, 保证重建图像能够达到预期的超分辨率要求, 依据单幅遥感图像纹理特征标记结果, 根据残差网络和纹理转移模型的训练过程, 进行超分辨率损失补偿。

分别从两个方面构建第一阶段重建图像和第二阶段重建图像, 其中, 第一阶段单幅遥感图像重建是获取与初始化低分辨率图像特征相同的高分辨率图像, 此时的重建结果为:

$$I_{\text{rebuild}}(x, y) = I(x, y) \otimes \tau_{\text{texture}} \tau_{\text{color}}^2 \quad (16)$$

将提取的遥感图像特征代入公式 (16) 中即可得出第一阶段图像的重建结果。

第二阶段图像重建的目的是进一步提升图像分辨率, 并对图像重建过程中可能存在的细节丢失情况进行补偿。

计算图像重建的细节损失值为:

$$\lambda = \frac{I_{\text{rebuild}}(x, y)}{2n_{\text{image block}}} \sum_{j=1}^{n_{\text{image block}}} r_{ij} \|b - V(b)\|^2, b \in I(x, y) \quad (17)$$

式中, b 和 $V(b)$ 分别为初始遥感图像的图像块及其网络映射值, $n_{\text{image block}}$ 表示单幅遥感图像中包含的图像块个数^[19-20]。假设单幅遥感图像的待重建分辨率目标为 μ , 那么单幅遥感重建图像的损失补偿函数如下:

$$G = I(x, y) + \lambda \cdot \mu \quad (18)$$

通过公式 (17) 和公式 (18) 的联立, 完成对单幅遥感重建图像的超分辨率损失补偿工作。

第二阶段单幅遥感图像的重建结果为：

$$I'_{\text{rebuild}}(x, y) = \lambda G[I_{\text{rebuild}}(x, y)] \quad (19)$$

最终对两个阶段得出的图像重建结果输入到残差网络和纹理转移模型的融合结构中，输出结果即为单幅遥感图像超分辨率重建结果。

2 实验

以测试所提方法的图像重建效果为目的，采用黑盒测试与对比测试相结合的方式设计实验。利用所提方法对准备的多个不同尺度遥感图像样本进行重建处理，得出对应的超分辨率处理结果和测试结果。

2.1 实验环境

从单幅遥感图像样本的准备和图像重建方法运行两个方面，对测试实验环境进行配置。遥感图像样本的采集设备包括飞行器、相机、云台等，飞行器选用的是 Mavic3Pro 型号的无人飞行器，该设备的最大飞行速度和飞行高度分别为 15 m/s 和 6 000 m，最大旋转角为 200°/s，有效像素为 2 000 万。由 MissionPlanner 提供的地面站软件控制飞行控制参数，利用 MissionPlanner 对 PixhawkSD 中记录的飞行数据进行分析，并对其进行有效航时、飞行稳定性等飞行特性的分析。搭载相机为 CMOS 相机装置，云台选用的是 MOY 无刷微单云台。为满足优化设计的融合残差网络和纹理转移模型的单幅遥感图像超分辨率重建方法的运行要求，网络搭建和测试的主要环境为 Windows10 系统，以 Python 系统应用语言为图像重建方法的开发工具，以 OpenCV 为图形处理平台，残差网络框架为 Tensorflow1。

2.2 实验样本

选择山地、耕地、森林、城市道路、居民区等区域作为遥感图像样本的采集区域，将准备的无人机装置放置在图像样本采集区域周围，采用固定快门模式，在考虑天气因素的情况下，根据不同的照明情况来确定拍摄时间，结合图像样本采集目标规划无人机的航行路线，在无人机内置控制器的作用下，实现无人机飞行路线的控制，并获取相应的遥感图像样本。

当其他条件不变时，摄像机的光圈参数也会影响到图像采集质量，所以也有必要设定光圈参数。为保证优化融合残差网络和纹理转移模型的单幅遥感图像超分辨率重建方法能够实现对多种不同尺度遥感图像的重建，分别生成大、小两种尺寸的图像样本，大图像尺寸为 1 200×1 600，小图像样本的尺寸分别为 700×1 000。部分遥感图像样本的准备情况如图 4 所示。



(a) 图像样本1 (b) 图像样本2

图 4 低分辨率遥感图像样本示意图

图 4 中，进行遥感图像筛选后，尽量不选择存在运动模糊的图像，保证遥感图像样本的初始分辨率均相同。

2.3 实验参数

由于所提方法应用了残差网络算法作为技术支持，因此需要对该算法的相关运行参数进行设定。

1) 学习速率：初始值设定为 0.001，即网络从初始状态开始学习时的步幅大小。每训练 30 个 epoch（即 30 个完整的数据集迭代），学习率衰减一半。帮助网络在初期更快地收敛，在训练后期进行更精细的调整。

2) 优化器：采用随机梯度下降法（SGD, stochastic gradient descent）训练网络。SGD 是一种常用的优化器，根据计算得到的梯度信息更新网络参数，以最小化损失函数。通过随机选择一小批次样本（批处理大小为 64），计算梯度并更新参数。

3) 正则化参数：设置权重衰减为 10^{-4} 。权重衰减是一种正则化技术，用于约束模型参数的大小，以提高模型的泛化能力和防止过拟合。

4) 批处理大小：设定为 64。批处理大小是一次迭代所使用的训练样本数。较大的批次大小可以加速训练过程，但会占用更多的内存。

5) 迭代轮数：设置为 50 轮。每一轮表示整个训练数据集被完整地传递给网络一次。通过多次迭代，可以使网络逐渐学习到更准确的特征表示和参数权重。

2.4 实验过程

1) 将图像重建程序代码导入主测计算机中，并将准备好的低分辨率遥感图像样本逐一输入到程序中。同时，从输入图像中随机选择图像块作为一个 batch。

2) 对每个 Batch 中的图像块进行 4 次下采样，从而获得被处理的图像重构目标。利用 3 个不同尺度的残差块，分别提取了图像的底层特征。残差块的数量被设定为 8。

3) 在特征标记结果的支持下，通过细节补充、图像融合等步骤，得出单幅遥感图像的超分辨率重建结果。

4) 重复上述操作可以得出实验中所有图像样本的超分辨率重建结果。在图像重建质量和效率测试过程中，设置实验对比项分别为基于锯齿空洞残差卷积的图像重建方法（文献 [1] 方法）和基于小波域的图像重建方法（文献 [2] 方法）。

2.5 实验指标

为了降低对单幅遥感图像超分辨率重建质量评价的主观性，设置峰值信噪比和分辨率作为图像重建质量的量化测试指标，式中，峰值信噪比的计算结果为：

$$\vartheta = 10 \lg \frac{I_{\text{max}}}{\epsilon} \quad (20)$$

式中， I_{max} 和 ϵ 分别为图像最大像素值和初始与重建图像的均方误差，变量 ϵ 的计算公式如下：

$$\epsilon = \frac{1}{D \times E} \sum_{x=1}^D \sum_{y=1}^E [I_{\text{rebuild}}(x, y) - I(x, y)]^2 \quad (21)$$

式中， D 和 E 分别为图像的长度和宽度， $I(x, y)$ 和

$I_{rebuild}(x, y)$ 为初始遥感图像样本和图像重建结果。另外重建分辨率指标的测试结果为：

$$\eta = \frac{E}{\Delta s} \quad (22)$$

式中, Δs 为重建图像中任意两个像素点之间的间距值。图像重建效率设置的测试指标为时间开销, 该指标的测试结果为：

$$T = t_{rebuild} - t_{start} \quad (23)$$

式中, t_{start} 和 $t_{rebuild}$ 分别为图像重建任务的起始时间和重建结果的输出时间。

2.6 实验结果

从大、小两个尺寸的遥感图像中随机选择 8 组进行测试, 通过相关数据的统计得出反映图像重建质量的测试结果。

提取遥感图像重建结果数据, 得出小尺寸遥感图像超分辨率重建质量的测试结果, 如图 5 和表 1 所示。



图 5 单幅遥感图像超分辨率重建结果

表 1 小尺寸遥感图像重建质量测试数据表

实验样本编号	基于锯齿空洞残差卷积的图像重建方法			基于小波域的图像重建方法			所提方法		
	I_{max}	ϵ	η /dpi	I_{max}	ϵ	η /dpi	I_{max}	ϵ	η /dpi
X1	570	5	720	600	5	720	585	2	1 080
X2	578	8	720	604	5	1 080	617	3	1 080
X3	574	5	720	588	4	560	594	2	1 080
X4	589	7	720	596	6	720	580	2	1 080
X5	564	6	560	578	4	720	525	1	1 080
X6	575	5	560	535	5	1 080	564	2	1 080
X7	580	8	720	560	5	720	606	2	1 080

由表 1 可知, 计算得出 3 种方法的峰值噪声比的平均值分别为 95.2、121.5 和 313.6, 通过平均值计算得出 3 种方法输出图像重建结果的平均值分辨率为 674、800 和 1 080 dpi。这是因为低分辨率图像在重建过程中提供了更多的信息和约束, 从而提高了图像重建的准确性和质量。通过在重建结果中平均化这些信息, 可以消除一部分随机噪声和伪影, 并强化真实细节的表达。相比单一低分辨率图像, 平均值分辨率结合了多个视角和采样的信息, 具有更好的全局一致性和真实性。此外, 由于多个低分辨率图像可能在不同区域具有不同的质量和信息, 通过平衡这些

差异, 并更好地保留并重建图像的细节和特征。

提取遥感图像重建结果中, 初始图像尺寸为 $1\ 200 \times 1\ 600$ 的结果数据, 得出反映中尺寸遥感图像超分辨率重建质量的测试结果, 如表 2 所示。

表 2 大尺寸遥感图像重建质量测试数据表

实验样本编号	基于锯齿空洞残差卷积的图像重建方法		基于小波域的图像重建方法		所提方法	
	峰值信噪比	分辨率 /dpi	峰值信噪比	分辨率 /dpi	峰值信噪比	分辨率 /dpi
Z1	91	560	120	720	311	1 080
Z2	93	720	118	720	304	1 080
Z3	92	560	116	560	312	1 080
Z4	95	720	106	720	299	1 080
Z5	89	560	117	720	289	1 080
Z6	88	720	104	720	313	1 080
Z7	91	560	111	560	307	1 080

由表 2 可知, 所提方法输出重建图像峰值信噪比和分辨率的平均值分别为 305 和 1 080 dpi。综合大、小两种尺寸遥感图像重建质量的测试结果, 证明所提方法的重建质量更高。

记录图像重建任务的启动时间和重建图像的输出时间, 计算得出 3 种方法重建效率的测试对比结果, 如图 6 所示。

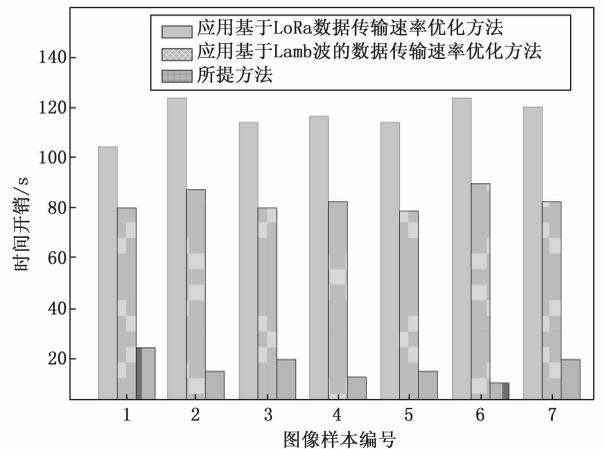


图 6 图像重建性能测试对比结果

从图 6 中可以看出, 3 种方法在运行图像重建任务时的时间开销约为 110、80 和 15 s, 由此证明所提方法具有更高的图像重建效率。这是因为在图像重建任务中, 采用了批处理技术, 即同时处理多个图像块或图像样本。通过一次性处理多个数据, 可以充分利用计算资源, 且采用更快速的卷积算法、减少冗余计算方式, 并发处理多个图像块或执行大规模矩阵运算等计算密集型操作。这样, 每个计算单元可以同时处理不同图像块的任务, 从而显著加快任务完成的速度。

3 结束语

遥感图像具有大幅宽、丰富纹理信息等特征, 同时也

极易受到环境与天气因素的影响, 出现纹理细节信息损失等问题, 为提高遥感图像有效信息的采集与提取效率, 保证遥感图像的应用价值, 设计并开发了遥感图像的超分辨率重建方法, 在融合残差网络和纹理转移模型的支持下, 通过特征标记与细节补充, 最大程度地实现图像纹理信息还原, 保证具有良好的图像重建质量和效率, 在实际工程项目中具有积极意义。然而, 受到时间和资源的限制, 此次实验设置的遥感图像样本数量较少, 因此得出的实验结果存在一定的局限性。

参考文献:

- [1] 李 岚, 蔺国梁, 马少斌. 基于锯齿空洞残差卷积的单幅图像超分辨率重建研究 [J]. 新疆大学学报 (自然科学版) (中英文), 2021, 38 (2): 174-190.
- [2] 董本志, 于明聰, 赵 鹏. 基于小波域的图像超分辨率重建方法 [J]. 液晶与显示, 2021, 36 (2): 317-326.
- [3] 贺温磊, 王朝立, 孙占全. 基于生成对抗网络的遥感图像超分辨率重建 [J]. 信息与控制, 2021, 50 (2): 195-203.
- [4] 李现国, 冯欣欣, 李建雄. 多尺度残差网络的单幅图像超分辨率重建 [J]. 计算机工程与应用, 2021, 57 (7): 215-221.
- [5] 尚晓梅, 李佳田, 吕少云, 等. 用于遥感图像超分辨率重建的残差对偶回归网络 [J]. 自然资源遥感, 2022, 34 (2): 112-120.
- [6] 刘 丛, 王亚新. 基于双并行残差网络的遥感图像超分辨率重建 [J]. 模式识别与人工智能, 2021, 34 (8): 760-767.
- [7] 魏一铭, 徐 岩, 王汇丰, 等. 基于多尺度与残差网络的图像超分辨率重建 [J]. 电光与控制, 2022, 29 (7): 102-107.
- [8] 原 铭, 李 凡, 李华锋, 等. 基于多级注意力密集残差网络的单幅图像超分辨率重建 [J]. 光学技术, 2022, 48 (3): 357-363.
- [9] 袁 健, 李佳慧. 融合先验信息的残差空间注意力人脸超分辨率重建模型 [J]. 小型微型计算机系统, 2023, 44 (5): 1035-1042.
- [10] 陈乔松, 宗 冕, 官暘珺, 等. 基于分形残差网络的单幅图像超分辨率重建 [J]. 重庆邮电大学学报 (自然科学版), 2022, 34 (1): 172-180.
- [11] 李亚超, 刘可文, 马 圆, 等. 基于残差注意力网络的图像超分辨率重建方法 [J]. 武汉理工大学学报, 2022, 44 (3): 87-90.
- [12] 王凡超, 丁世飞. 基于广泛激活深度残差网络的图像超分辨率重建 [J]. 智能系统学报, 2022, 17 (2): 440-446.
- [13] 耿铭昆, 吴凡路, 王 栋. 轻量化火星遥感影像超分辨率重建网络 [J]. 光学精密工程, 2022, 30 (12): 1487-1498.
- [14] 王 建, 徐俊章, 宋 巍, 等. 参考图像特征迁移的遥感影像超分辨率重建 [J]. 测绘科学, 2022, 47 (12): 156-164.
- [15] 陈 楠, 张 标. 多尺度半耦合卷积稀疏编码的遥感影像超分辨率重建 [J]. 计算机辅助设计与图形学学报, 2022, 34 (3): 382-391.
- [16] 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 [J]. 武汉大学学报 (信息科学版), 2021, 46 (11): 1716-1726.
- [17] 胡 诚, 曹春阳, 徐晨光, 等. 基于深度学习的单幅图像超分辨率重建算法综述 [J]. 黑龙江科学, 2023, 14 (8): 31-33.
- [18] 陈 磊, 陈 颖, 李文举, 等. 残差块改进暹罗网络的遥感图像配准 [J]. 计算机仿真, 2022, 39 (3): 224-229.
- [19] 郑 艳, 何 欢, 卜丽静, 等. 自相似性和边缘保持分解的超分辨率重建算法 [J]. 测绘通报, 2022 (7): 54-59.
- [20] 柏宇阳, 朱福珍, 巫 红. 改进的密集连接网络遥感图像超分辨率重建 [J]. 高技术通讯, 2021, 31 (10): 1037-1043.
- [1] 李 岚, 蔺国梁, 马少斌. 基于锯齿空洞残差卷积的单幅图像超分辨率重建研究 [J]. 新疆大学学报 (自然科学版) (中英文), 2021, 38 (2): 174-190.
- [2] 董本志, 于明聰, 赵 鹏. 基于小波域的图像超分辨率重建方法 [J]. 液晶与显示, 2021, 36 (2): 317-326.
- [3] 贺温磊, 王朝立, 孙占全. 基于生成对抗网络的遥感图像超分辨率重建 [J]. 信息与控制, 2021, 50 (2): 195-203.
- [4] 李现国, 冯欣欣, 李建雄. 多尺度残差网络的单幅图像超分辨率重建 [J]. 计算机工程与应用, 2021, 57 (7): 215-221.
- [5] 尚晓梅, 李佳田, 吕少云, 等. 用于遥感图像超分辨率重建的残差对偶回归网络 [J]. 自然资源遥感, 2022, 34 (2): 112-120.
- [6] 刘 丛, 王亚新. 基于双并行残差网络的遥感图像超分辨率重建 [J]. 模式识别与人工智能, 2021, 34 (8): 760-767.
- [7] 魏一铭, 徐 岩, 王汇丰, 等. 基于多尺度与残差网络的图像超分辨率重建 [J]. 电光与控制, 2022, 29 (7): 102-107.
- [8] 原 铭, 李 凡, 李华锋, 等. 基于多级注意力密集残差网络的单幅图像超分辨率重建 [J]. 光学技术, 2022, 48 (3): 357-363.
- [9] 袁 健, 李佳慧. 融合先验信息的残差空间注意力人脸超分辨率重建模型 [J]. 小型微型计算机系统, 2023, 44 (5): 1035-1042.
- [10] 陈乔松, 宗 冕, 官暘珺, 等. 基于分形残差网络的单幅图像超分辨率重建 [J]. 重庆邮电大学学报 (自然科学版), 2022, 34 (1): 172-180.
- [11] 李亚超, 刘可文, 马 圆, 等. 基于残差注意力网络的图像超分辨率重建方法 [J]. 武汉理工大学学报, 2022, 44 (3): 87-90.
- [12] 王凡超, 丁世飞. 基于广泛激活深度残差网络的图像超分辨率重建 [J]. 智能系统学报, 2022, 17 (2): 440-446.
- [13] 耿铭昆, 吴凡路, 王 栋. 轻量化火星遥感影像超分辨率重建网络 [J]. 光学精密工程, 2022, 30 (12): 1487-1498.
- [14] 王 建, 徐俊章, 宋 巍, 等. 参考图像特征迁移的遥感影像超分辨率重建 [J]. 测绘科学, 2022, 47 (12): 156-164.
- [15] 陈 楠, 张 标. 多尺度半耦合卷积稀疏编码的遥感影像超分辨率重建 [J]. 计算机辅助设计与图形学学报, 2022, 34 (3): 382-391.
- [16] 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 [J]. 武汉大学学报 (信息科学版), 2021, 46 (11): 1716-1726.
- [17] 胡 诚, 曹春阳, 徐晨光, 等. 基于深度学习的单幅图像超分辨率重建算法综述 [J]. 黑龙江科学, 2023, 14 (8): 31-33.
- [18] 陈 磊, 陈 颖, 李文举, 等. 残差块改进暹罗网络的遥感图像配准 [J]. 计算机仿真, 2022, 39 (3): 224-229.
- [19] 郑 艳, 何 欢, 卜丽静, 等. 自相似性和边缘保持分解的超分辨率重建算法 [J]. 测绘通报, 2022 (7): 54-59.
- [20] 柏宇阳, 朱福珍, 巫 红. 改进的密集连接网络遥感图像超分辨率重建 [J]. 高技术通讯, 2021, 31 (10): 1037-1043.
- [1] 田连辉. 家庭抽油烟机的油烟净化技术 [J]. 现代制造技术与装备, 2022, 12: 162-164.
- [2] 舒木水, 淡 默, 纪晓慧. 油烟净化设备对餐饮排放物的净化效率 [J]. 环境工程, 2018, 36 (11): 81-84.
- [3] 肖玥伶, 孙一鸣, 罗 金, 等. 餐饮油烟排放对大气污染的影响及管控 [J]. 环境科学与技术, 2021, 44 (s1): 217-222.
- [4] 李 剑, 付成冲, 王伯燕, 等. 集成灶油烟净化性能测试研究 [J]. 中国标准化, 2021, 9: 186-189.
- [5] 伍 培, 彭江华, 郑 洁. 利用负离子的油烟多级净化装置的研究探讨 [J]. 工业安全与环保, 2016, 42 (4): 23-26.
- [6] 芦照炬, 徐凤珍, 龙顺宇. 基于 STC8H 单片机的多功能雾化器设计 [J]. 电子制作, 2023, 2: 8-12.
- [7] 徐良雄, 徐炎炎. 智能抽油烟机的设计 [J]. 实验室研究与探索, 2012, 31 (9): 204-206.
- [8] 马景赞, 莫杏梅. 餐饮业油烟净化行业发展现状 [J]. 中国环保产业, 2020, 9: 25-28.
- [9] 张 星, 钱振清, 张德峰, 等. 餐饮油烟排放特征与净化技术
- [10] 田连辉. 家庭抽油烟机的油烟净化技术 [J]. 现代制造技术与装备, 2022, 12: 162-164.
- [11] 张秀喜, 丁志伟, 韩东梅, 等. 家庭厨房油烟污染现状分析与对策 [J]. 绿色科技, 2017, 9: 19-21.
- [12] 孙冠文. 超声波雾化技术在油烟净化上的应用研究 [D]. 广州: 广东工业大学, 2008.
- [13] 张云鹏, 张欢欢. 基于智慧监管理念的五段式一体化油烟净化系统设计 [J]. 工业安全与环保, 2022, 48 (6): 103-106.
- [14] 吴 萍, 曾智忠. 智能抽油烟机控制器的研制 [J]. 电子测试, 2022, 17: 8-11.
- [15] 刘 智, 曲绍鹤. 带循环净化单元的吸油烟机及污染控制技术 [J]. 家电科技, 2022, 1: 28-31.
- [16] 李晓旭, 苗 琪. 机械离心复合静电技术去除油烟实验研究 [J]. 辽宁石油化工大学学报, 2019, 39 (2): 43-46.
- [17] 于鸿飞. 一种湿度智能调节雾化器的设计研究 [J]. 电子世界, 2018, 8: 173-175.