

低秩张量嵌入的高光谱图像去噪神经网络

涂坤¹, 熊凤超¹, 侯雪强²

1. 南京理工大学计算机科学与工程学院, 南京 210094;

2. 中国酒泉卫星发射中心, 酒泉 732750

摘要: 随着遥感卫星技术的快速发展, 高光谱图像在环境检测、资源管理、农业预警等领域得到了广泛应用。然而, 由于设备误差和大气因素等原因, 采集的高光谱图像中常常存在噪声, 这会影响后续任务的准确性。因此, 高光谱图像去噪成为了一个重要的研究方向。高光谱图像的空间关联、光谱关联和空间-光谱联合关联导致干净的高光谱图像存在低维子空间中。低秩先验是高光谱图像普遍的物理性质, 然而基于低秩表示的方法通常需要复杂的参数设置和计算。基于深度学习方法直接从数据中学习到干净图像的先验信息, 具有较强的表达能力, 但依赖大量数据且缺乏对高光谱图像物理知识如低秩性的有效利用。为了解决这些问题, 本文利用高光谱图像的空间-光谱低秩特性, 提出一种低秩张量嵌入深度神经网络方法, 可以有效去除高光谱图像中的噪声。该方法采用低秩张量分解模块对高光谱图像的特征图进行低秩表示, 通过全局池化和卷积等操作完成秩一向量的生成和低秩张量的重构。同时, 将低秩张量分解模块与 Unet 相结合, 对浅层特征进行低秩张量表示, 以捕捉高光谱图像的空间-光谱低秩特性, 提高了模型的去噪能力。当噪声标准差在 $[0-95]$ 时, 算法可以取得 41.02 dB 的 PSNR 和 0.9888 的 SSIM。仿真数据和真实数据实验结果表明, 所提出的低秩深度神经网络方法去噪效果优于其他方法。

关键词: 高光谱图像去噪, 深度神经网络, 低秩张量表示, 知识驱动深度学习, CP 分解, U-Net

中图分类号: TP751/P2

引用格式: 涂坤, 熊凤超, 侯雪强. 2024. 低秩张量嵌入的高光谱图像去噪神经网络. 遥感学报, 28(1): 121-131

Tu K, Xiong F C and Hou X Q. 2024. Low-rank tensor embedded deep neural network for hyperspectral image denoising. National Remote Sensing Bulletin, 28(1): 121-131 [DOI: 10.11834/jrs.20243119]

1 引言

高光谱图像同时记录目标的空间信息和对不同波长的光谱反射, 在复杂场景下目标检测 (Lone 等, 2022)、地物分类 (Zhu 等, 2022)、变化检测 (Wang 等, 2022) 等领域有着重要的应用价值。然而, 高光谱成像过程中受到设备和环境的影响, 难免会产生各种噪声, 导致图像质量下降, 极大地影响了高光谱图像的应用价值。因此, 对高光谱图像进行去噪是利用其进行后续分析的必要预处理步骤。

高光谱图像去噪的关键是干净高光谱图像进行内容建模。高光谱图像的光谱关联特性导致干净高光谱图像存在低维光谱子空间中, 形成光谱

低秩特性; 空间的局部和非局部关联导致干净高光谱图像的空间维也存在低秩性。因此, 干净的高光谱图像具有低秩特性。有效地刻画高光谱图像的低秩特性可以更好地对高光谱图像进行去噪 (Fu 等, 2015, Peng 等, 2022)。低秩矩阵恢复 LRMR (Low-rank Matrix Recovery) 理论, 认为干净高光谱图像具有低秩特性, 通过低秩分解或低秩近似对高光谱图像进行重建, 从而达到去除噪声目的。Zhang 等 (2014) 利用 LRMR 理论将高光谱图像沿着空间维重新排成二维矩阵进行去噪。该方法可以同时去除高斯噪声、脉冲噪声、死线噪声和条纹噪声, 但该方法将单波段图像转换为一列元素, 忽略了图像的空间关系。Wang 等 (2016) 提出一种基于分组低秩表示算法, 认为传统的低

收稿日期: 2023-04-10; 预印本: 2023-11-09

基金项目: 国家自然科学基金(编号: 62002169); 江苏省自然科学基金(编号: BK20200466)

第一作者简介: 涂坤, 研究方向为高光谱图像去噪。E-mail: 2550277604@qq.com

通信作者简介: 熊凤超, 研究方向为遥感影像处理、模式识别、计算机视觉、机器学习。E-mail: fcxiong@njjust.edu.cn

秩表示方法仅仅利用了图像的局部信息,因此无法充分挖掘图像中的信息。该算法首先将高光谱图像划分为若干组,每组由相似的图片块构成;然后根据每个组内部的局部相似性以及组内图像块之间的非局部相似性,采用低秩表示方法进行重建。这种方法可以更好地利用图像中的非局部相似性信息,提高了高光谱图像的去噪效果。Zhuang等(2018)提出了一种快速高光谱图像去噪算法,称为FastHyDe。该方法将高光谱图像转换到低维子空间,并利用高光谱图像的低秩性和子空间中图像的自相似性来进行去噪,对于加性噪声和泊松噪声有更好的去噪效果。然而,将高光谱图像重排列为二维矩阵进行去噪,忽略了高光谱图像空间相关性,从而导致图像细节信息的丢失或者失真,进而影响去噪效果。

基于张量表示的方法直接把高光谱图像看作是一个三阶张量,能够更充分地利用高光谱图像在空间、光谱以及空间-光谱联合信息,从而提高去噪效果。Liu等(2012)提出了一种基于Canonical Polyadic (CP)分解的并行因子分析模型,通过将张量因子转换为秩为1的张量的和,实现了对高光谱图像的去噪处理。此外,通过加性噪声的方差评估张量分解的秩,确定最佳的张量分解结果。Guo等(2013)提出了一种基于高阶秩一张量分解(RITD)的高光谱图像去噪方法。该方法首先使用CP分解将高光谱图像分解为一组秩为1的张量,然后对这些张量进行排序,排名靠前的被认为是图像中的主要成分。通过对主成分的拼接,可以还原原始图像,并实现去噪处理。前面提到的两种方法都只考虑了高光谱图像的全局相关性,无法充分利用高光谱图像的非局部相似性。为了解决这个问题,Xue等(2019)提出了一种非局部低秩正则化CP张量分解(NLR-CPTD)模型,将高光谱图像划分为多个非局部相似的数据块,并将这些数据块展开后进行拼接,采用低秩张量正则化方法更充分地利用高光谱图像的非局部相似性,从而提高了去噪效果。Zheng等(2020)提出了3DLogTNN模型在张量奇异值分解的基础上进行了拓展,引入了三方向基于对数的张量核范数,以获取更精确的解。

基于低秩表示的高光谱图像去噪方法需要手动设置模型超参数和先验,进行多次迭代和调参,容易陷入次优解,从而导致去噪效果不佳。相比

之下,基于深度学习的方法可以通过学习数据集来不断更新网络参数,具有强大的学习能力,从而在去噪方面取得更好的效果(吴从中等,2020)。Zhang等(2017)在图像去噪方面,提出了深度卷积神经去噪网络(DnCNN),该网络完全通过卷积神经网络进行图像去噪。Çiçek等(2016)将2D U-net(Ronneberger等,2015)进行拓展,提出了更适合处理三维数据的3D U-net,并在卷积操作后添加了批量正则化(Batch Normalization)来加速收敛。Dong等(2019)结合高光谱数据的特点设计了3D卷积神经网络,在3D U-net的基础上提出了可分离滤波策略的3D U-net,将3D滤波分解为2D空间滤波和1D光谱滤波,以分别提取空间和光谱特征,以减少计算量。Wei等(2021)提出的3D准递归神经网络QRNN3D(3-D Quasi-Recurrent Neural Network)通过3D卷积从相邻的波段间提取空间光谱特征,并取得了优秀的去噪结果。将残差网络与边缘增强相结合,通过多尺度信息的利用提高遥感图像的去噪效果。深度学习方法对数据的依赖性较高,缺乏对高光谱图像知识的有效利用,泛化能力较差。

本文结合基于模型方法和基于深度学习方法的优点,将高光谱图像的低秩先验和深度神经网络的表征能力相结合,提出了一种新的高光谱图像去噪方法,称为LR-Unet。该方法采用基于CP分解的低秩张量生成模块,将高光谱图像的低秩先验知识嵌入到深度神经网络中,刻画高光谱图像的空间-光谱低秩结构,以更好地恢复干净高光谱图像。

2 低秩神经网络模型结构

针对高光谱图像去噪问题,本文提出一种低秩神经网络,如图1所示。该网络基于Unet结构,在多个尺度上采用编码器-解码器结构进行特征提取和重构,以恢复图像的细节和结构。为了提取局部空间-光谱特征,本文使用了三维卷积代替了二维卷积。同时,本文考虑了高光谱图像的低秩先验,基于CP分解提出了一种低秩张量生成模块。通过控制CP分解时秩一张量的最小个数,可以保证图像张量的低秩性。该模块针对浅层特征进行张量分解与重建,引导网络对高光谱图像进行修复。下面本文将详细介绍编码器-解码器和低秩张量生成模块。




图1 LR-Unet网络结构(网络主干是多层编码器—解码器结构,同层的编码器与解码器之间使用跳跃连接;另外,使用了一个低秩张量生成模块,通过Hadamard积嵌入到网络)

Fig. 1 LR-Unet network architecture (The network backbone consists of a multi-layer encoder-decoder structure with skip connections between corresponding layers of the encoder and decoder. Additionally, a low-rank tensor generation module is employed and embedded into the network through Hadamard product)

2.1 编码器—解码器

多层编码器—解码器结构逐步在不同尺度上提取高光谱图像的浅层纹理信息和深层结构特征。编码器通过对输入的图片进行特征抽取和下采样,随着网络加深,图像的空间分辨率越来越低,特征维度逐渐升高,同时网络提取到了不同尺度的特征。解码器对输入的特征进行不断地上采样,随着网络加深,图像的空间分辨率逐渐加大,同时特征维度降低。为了避免梯度消失和梯度爆炸问题,并加快网络的收敛速度,本文使用跨层连接来连接编码器和解码器。编码/解码器的结构由三维卷积(Conv3d)、批量归一化(BatchNorm3d)和激活函数(ReLU)组成。三维卷积可以提取空间—光谱信息,卷积核大小设置为 $3 \times 3 \times 3$,步长为 $1 \times 1 \times 1$;批量归一化将输入的特征数据标准化到正态分布,从而提高网络的收敛速度和模型的泛化能力;激活函数引入非线性关系,有助于网络拟合目标函数。编码器之间使用MaxPool3d下采样连接,而解码器之间使用ConvTranspose3d上采样连接。这种多层结构能够分别处理不同层次的特征信息。浅层特征提取具有较小的感受野,

可以获取到图像的纹理信息,从而帮助修复图像的细节。而深层特征提取具有较大的感受野,可以获取更深层次的语义信息。以高光谱图像 X_0 作为输入, N 层编码器可以表达为

$$\begin{cases} X_1 = \text{Encoder}_1(X_0) \\ X_i = \text{Encoder}_i(\text{MaxPool}(X_{i-1})) \quad i = 2, 3, \dots, N \\ O = \text{Conv3d}(\text{MaxPool}(X_N)) \end{cases} \quad (1)$$

$$\begin{cases} X'_N = \text{DeConv}(O) \\ X'_{i-1} = \text{DeConv}(\text{Decoder}_i(\text{Cat}(X'_i, X_i))) \\ i = N, N-1, \dots, 1 \\ \hat{X} = \text{Conv3d}(X'_0) \end{cases} \quad (2)$$

式中, Decoder_i 表示第 i 层解码器, X'_N 表示解码器的输出, $\text{DeConv}(\cdot)$ 表示ConvTranspose3d上采样操作。 $\text{Cat}(\cdot, \cdot)$ 从通道维拼接上层的输出和对应层的解码器输出。多层解码器之后,本文使用Conv3d($\cdot$)进行图像重构,还原出干净图像 X' 。在本文的实现中采用了4层编码器—解码器结构的设置,以一个波段数目、长、宽分别为 B 、 H 、 W 的高光谱图像 $X_0 \in \mathbb{R}^{B \times H \times W}$ 作为输入,其中每层编码/解码器及上采样和下采样层的具体参数如表1所示。

表1 各模块参数设置

Table 1 The parameters settings of each module

	输入通道	输出通道	输出尺寸
编码器1	1	16	$B \times H \times W$
下采样	16	16	$B \times \frac{H}{2} \times \frac{W}{2}$
编码器2	16	32	$B \times \frac{H}{2} \times \frac{W}{2}$
下采样	32	32	$B \times \frac{H}{4} \times \frac{W}{4}$
编码器3	32	64	$B \times \frac{H}{4} \times \frac{W}{4}$
下采样	64	64	$B \times \frac{H}{8} \times \frac{W}{8}$
编码器4	64	128	$B \times \frac{H}{8} \times \frac{W}{8}$
下采样	128	128	$B \times \frac{H}{16} \times \frac{W}{16}$
编码器 Conv3d	128	256	$B \times \frac{H}{16} \times \frac{W}{16}$
上采样	256	128	$B \times \frac{H}{8} \times \frac{W}{8}$
解码器4	256	128	$B \times \frac{H}{8} \times \frac{W}{8}$
上采样	128	64	$B \times \frac{H}{4} \times \frac{W}{4}$
解码器3	128	64	$B \times \frac{H}{4} \times \frac{W}{4}$
上采样	64	32	$B \times \frac{H}{2} \times \frac{W}{2}$
解码器2	64	32	$B \times \frac{H}{2} \times \frac{W}{2}$
上采样	32	16	$B \times H \times W$
解码器1	32	16	$B \times H \times W$

注: B 、 H 、 W 分别为高光谱图像的波段数目、长、宽。

2.2 低秩张量生成模块

高光图像的空间关联、光谱关联和空间—光谱联合关联导致干净的高光谱图像存在低维子空间中, 可以由低秩张量分解刻画。本文采用 CP 分解描述高光谱图像在特征维的低秩性。具体而言, CP 分解是将任意 n 阶张量 $\mathcal{F}$ 分解为 R 个秩一张量的线性组合, 即

$$\mathcal{F} = \sum_{r=1}^R \lambda_r \mathbf{a}_r \circ \mathbf{b}_r \circ \mathbf{c}_r \quad r = 1, 2, \dots, R \quad (3)$$

式中, “ $\circ$ ” 表示向量外积, $\mathbf{a}_r$ 、 $\mathbf{b}_r$ 、 $\mathbf{c}_r$ 分别为秩一张量的成员向量代表着图像中不同的特征信息 (Zhang 等, 2021), λ_r 为秩一张量的权重。

对于一个通道数为 C 的高光谱图像特征 $\mathcal{X} \in \mathbb{R}^{C \times B \times H \times W}$, 本文将它切分成 C 个特征张量 $\mathcal{F} \in \mathbb{R}^{B \times H \times W}$, 然后采用秩一张量生成模块模拟 CP 分解对其低秩特性进行刻画。如图2, 对于输入的特征张量 $\mathcal{F}$, 秩一张量生成模块使用全局平均池化

分别在长度、宽度、波段维收集上下文信息。再通过卷积和 Sigmoid 的非线性映射求得每个维度的秩一向量: $\mathbf{a}_r$ 、 $\mathbf{b}_r$ 、 $\mathbf{c}_r$ 。最后使用 Kronecker 积重构 3 个秩一向量:

$$\mathcal{G}_r = \mathbf{a}_r \circ \mathbf{b}_r \circ \mathbf{c}_r \quad (4)$$

得到的 $\mathcal{G}_r$ 是包含了空间—光谱关联的秩一张量。




图2 秩一张量生成模块(包含三个维度的分量提取和秩一张量的生成)

Fig. 2 Rank-1 Tensor Generation Module (It includes three-dimensional component extraction and rank-1 tensor generation)

如图2下半部分所示, 在每个秩一张量生成后从特征张量中减去生成结果再作为下一个秩一张量生成模块的输入, 从特征张量 $\mathcal{F}$ 中剔除每个秩一张量 $\mathcal{G}_r$ 是为了避免计算相等的秩一张量, 同时, 后面的秩一张量会加上前面的秩一张量, 以避免信息过度丢失。最后, 在计算完所有的秩一张量后, 本文通过拼接的方式将它们聚合成一个低秩张量。为了更有效地恢复高频信息, 在聚合的过程中, 本方法从低频到高频方向添加了残差连接。然后, 本文使用二维卷积 (Conv2d) 来学习各个通道的秩一张量的权重, 并最终得到低秩张量。最后, 通过将低秩张量和输入特征进行 Hadamard 积运算, 本文可以细化图像特征并得到低秩的高光谱图像特征图 $\mathcal{F}'$ 。在本文的低秩神经网络中, 使用这个特征图来替代最后一层解码器中的跳跃连接, 以对整个网络添加低秩约束:

$$\mathcal{X}'_0 = \text{DeConv}(\text{Decoder}_1(\text{Cat}(\mathcal{X}'_1, \mathcal{F}')) \quad (5)$$

3 实验结果与分析

本实验使用 ICVL 数据集 ([http://icvl.cs.bgv.ac.il/hyperspectral\[2023-04-10\]](http://icvl.cs.bgv.ac.il/hyperspectral[2023-04-10])) 进行仿真实验。从 ICVL 数据集中选择了 100 幅图像作为训练集, 另外 50 幅图像构成了测试集。每幅图像的原始大小为 $1392 \times 1300 \times 31$ 。在训练过程中, 本文选择了大小为 $64 \times 64 \times 31$ 的子图像来进行网络训练。本文切取中间位置大小为 $512 \times 512 \times 31$ 的图像用于测试。

为了模拟真实噪声图像, 对干净高光谱图像每个波段加入不同标准差的均值为零的加性高斯

噪声以产生噪声—干净图像对，其中，标准差 σ 在 $[0-95]$ 之间。最后，为了测试算法在真实数据上的性能，本文选择了 Urban 数据和 Indian Pines 数据作为测试数据集。

为了进行对比，分别选取了基于稀疏的传统算法如 BM4D (Maggioni 等, 2013)、TDL (Peng 等, 2014)、MTSNMF (Ye 等, 2015)，基于低秩的方法 LLRT (Chang 等, 2017)、3DLogTNN (Zheng 等, 2020) 以及基于深度学习算法：QRNN3D (Wei 等, 2021)、SMDS-Net (Xiong 等, 2022)、MAC-Net (Xiong 等, 2022) 等方法进行对比。

3.1 评价指标

论文中的定量对比指标包括峰值信噪比 PSNR (Peak Signal-to-Noise Ratio)、结构相似度 SSIM (structural similarity)、光谱角制图 SAM (Spectral Angle Mapper) 等，并且选取了部分高光谱图像和相关像素点进行了可视化处理作为展示。峰值信噪比是图像有损变换（如图像去噪、图像压缩等）中最普遍和使用最广泛的客观指标之一。主要基于像素点之间的误差进行计算，PSNR 的值越大说明两张图的像素点越接近，图像恢复的就更好。结构相似度基于亮度、对比度和结构方面分别进行比较，与人类视觉系统 (HVS) 的质量感知相关。光谱角可以用来衡量干净高光谱图像和去噪后的高光谱图像之间的光谱相似度。其值越小说明去噪的结果越接近真实值。

3.2 网络实现

本实验的所有代码使用 PyTorch 完成，算法初

始学习率为 5×10^{-4} ，分别在第 10 轮时、30 轮时、60 轮时以 0.1 的倍数进行下降，总迭代次数为 70 轮，采用 Adam 优化器进行参数更新。LR_Unet 采用均方差 MSE (Mean Square Error) 作为网络损失函数，用于衡量网络输出样本与目标输出样本之间的差异。给定 N 个噪声—干净图像样本对，对应的损失函数定义为

$$L = \frac{1}{N} \sum_{n=1}^N \|X^{(n)} - \hat{X}^{(n)}\|_F^2 \quad (6)$$

式中， $X^{(n)}$ 和 $\hat{X}^{(n)}$ 分别是输入的噪声图像和输出的修复图像。

3.3 仿真数据实验

本文在 ICVL 数据集上统计了不同方法的去噪结果，并与本实验方法进行了对比，其定量结果如表 2 所示。从表 2 中数据可以看出，单独基于低秩和稀疏的方法可以在高光谱图像去噪中取得一定程度的效果。然而，基于深度学习的方法，如 QRNN3D、SMDS-Net 和 MAC-Net，在去噪表现上相较于基于低秩和稀疏方法表现更优，去噪后的高光谱图像能够获得更高的 PSNR。这种差异的原因在于，当面临复杂的噪声情况时，图像能够提供的有效信息减少。传统的基于模型的方法很难仅依靠有限的信息进行建模。而深度学习方法通过基于大规模数据集的学习，可以通过优化器对网络参数进行更新，从而使网络能够获得更好的去噪效果。得益于低秩张量生成模块对高光谱图像数据的低秩性的刻画，本方法的去噪结果取得了最好的数值指标。

表 2 不同方法在 ICVL 数据集去噪效果对比
Table 2 Comparison of different methods on ICVL dataset

指标	稀疏方法			低秩方法		深度学习方法			
	BM4D	TDL	MTSNMF	3DLogTNN	LLRT	QRNN3D	SMDS-Net	MAC-Net	LR_Unet
PSNR	35.27	25.40	34.20	24.53	32.49	37.66	39.34	<u>40.17</u>	41.02
SSIM	0.8764	0.3735	0.7998	0.4251	0.7191	0.9479	0.9593	<u>0.9837</u>	0.9888
SAM	0.0799	0.3641	0.2128	0.6087	0.1687	0.0468	0.0303	0.0358	<u>0.0304</u>

注：加粗字体为每行最优值，下划线标注字体为次优值。

为了直观的展示去噪结果，本文选取了 ICVL 数据集的高光谱图像 ulm_0328-1118 进行了可视化展示。结果如图 3 所示，其中图 3 (a) 表示干净图像，图 3 (b) 表示添加加性高斯噪声后的图像，而其他图像展示了各种对比方法的去噪结果。可以看到 BM4D (图 3(c)) 和 MTSNMF (图 3(e)) 的

去噪结果图像存在过度平滑的问题，导致图像中的细节信息丢失。TDL 方法 (图 3(d)) 很难处理严重噪声的图像。3DLogTNN 的去噪结果 (图 3(f)) 中仍然包含有明显的噪声痕迹。LLRT 的去噪结果 (图 3(g)) 中部分区域出现了失真现象。SMDS-Net 的去噪图像 (图 3(i)) 中丢失了部分细节信息。

从图3(k)中的可视化结果来看,本方法在去噪高光谱图像方面表现出色。通过添加低秩约束,并利用多尺度信息,使得经过去噪的图像几乎没

有噪声,并且保留了丰富的细节信息。这进一步验证了本方法在处理高光谱图像去噪任务中的有效性。




图3 ICVL数据集中图像ulm_0328-1118的去噪结果,噪声标准差为[0—95],伪彩色图像通过结合波段6、15和25生成
Fig. 3 Denoising results for the ulm_0328-1118 image in the ICVL Dataset with the noise variance in [0—95] (The false-color images were generated by combining bands 6, 15, 25)

为了辅助分析,论文中选取了该图像中的一个像素点(201, 201)绘制出了光谱曲线。如图4所示,其中图4(b)表示干净图像中该点对应的的光谱曲线,图4(c)由于添加了噪声,导致不同波段之间出现明显的起伏。通过对比去噪结果展示和图4中的光谱曲线,可以得到以下观察结果:BM4D、MTSNMF、QRNN3D、SMDS-Net对应的光谱曲线都变得较为平滑。这与去噪结果的展示相吻合。图4(i)展示的是本方法的去噪结果,由于本方法利用了高光谱图像数据的低秩性,并通过数据驱动的方式学习到高光谱图像空间—光谱关系,因此去噪结果的光谱曲线更接近干净图像的光谱曲线。

3.4 真实数据实验

本文采用在ICVL训练集得到的深度模型进行真实数据实验。在实际实验中,我们对高光谱数据的波段进行切分,以保证和ICVL数据具有相同数目波段。Urban数据每个波段的图像大小为 307×307 像素,其中每个像素对应现实世界中一个 $2\text{ m} \times 2\text{ m}$ 的区域,Urban数据具有210个波段,范围从400 nm到2500 nm,光谱分辨率为10 nm。从图5(a)可以看出,真实数据中存在不同形式的噪

声,如高斯噪声、条纹噪声等。LR-Unet将Urban数据每31个波段进行切分,分别对每个切分后的31波段高光谱图像进行去噪,将得到的结果进行汇总得到最后的输出。如图5(c)和图5(f)所示,基于模型的方法如TDL、LLRT方法面对复杂的噪声表现较差,BM4D、MTSNMF、3DLogTNN等方法尽管去除了部分噪声,但是还有明显的条纹噪声遗留。基于深度学习的方法QRNN3D和SMDS-Net在面对未曾作为训练集的噪声也展现出了较强的去噪能力。图5(i)展示了本方法的去噪结果,结合高光谱图像的低秩先验和多尺度特性,本文方法取得了较好的去噪效果。

除了上文展示的可视化结果,本文选取图像中像素点(120, 150)绘制出了对应的光谱曲线以辅助定性分析,其结果如图6所示。可以看出图6(a)原始图像中该点对应的的光谱曲线波动比较明显。在经过去噪算法处理后,各方法的结果显示的光谱曲线都发生了变化。基于模型的方法对应的变化较弱,从前面的可视化结果也可以看出这些方法并没有能很好的去除图像中存在的噪声。图6(i)展示了本文方法的去噪图像的光谱曲线,可以看出光谱曲线变得平滑的同时本文的方法还保留了图像波段间的结构差异性。




图4 高光谱图像 ulm_0328-1118 中像素 (201,201) 的光谱去噪结果

Fig. 4 Denoising results of pixel (201,201) in the ulm_0328-1118 HSI




图5 真实数据Urban高光谱图像的去噪结果,伪彩色图像通过结合波段3、108、208生成

Fig. 5 Denoising results on real-world Urban HSI. The false-color images were generated by combining bands 3, 108, 208

除了Urban数据外,本文还在Indian Pines数据进行了测试,该数据由机载可见红外成像光谱仪(AVIRIS)拍摄,拍摄内容是美国印第安纳州

一块印度松树林,数据大小为 $145 \times 145 \times 220$,图像的空间分辨率为20 m。MTSNMF方法(图7(d))尽管去除了图像中的发部分高斯噪声,但仍有比

较明显的条纹噪声遗留。如图 7 (g) (h) 所示, 基于深度学习的方法取得了较好的去噪结果。本方法测试结果如图 7 (i) 所示, 本方法能够去除

图像中存在的大部分噪声, 并且能够较为明显的看出图像中各部分的边缘信息。




图6 Urban 数据集点(120,150)的光谱去噪结果

Fig. 6 Denoising results of pixel (120,150) in the Urban HIS




图7 真实数据Indian Pines 高光谱图像的去噪结果,伪彩色图像通过结合波段1,31,189生成

Fig. 7 Denoising results on real-world Indian Pines HSI. The false-color images were generated by combining bands 1, 31, 189

3.5 消融实验

为了验证低秩张量分解模块的有效性，本文进行了消融实验，并在表3中展示了结果。实验结果表明，当仅使用CP分解或Unet时，分别仅能达到32.8055 dB和39.4292 dB的去噪性能。然而，当将CP分解嵌入到Unet中以捕捉高光谱图像特征的低秩性时，本文的LR_Unet能够取得更高的去噪性能。因此，本文提出的低秩分解模块对于高光谱图像去噪是有益的。

表3 关于秩一张量生成模块消融实验

Table 3 Ablation study on the rank-1 generation module

Unet	CP	PSNR
	√	32.8055
√		39.4292
√	√	41.0256

为了研究不同CP秩对网络性能的影响，本文设计了实验，并根据CP分解的秩设置了不同的参数。实验结果如图8所示。从实验结果可以看出，不同的秩会对去噪性能产生影响。在秩为2的情况下，本文取得了最佳的去噪效果。然而，随着秩的增大，去噪性能反而下降。这说明高光谱图像具有良好的低秩性质。此外，由于网络通过卷积操作来为不同的低秩张量赋予权重，过大的秩值会导致卷积核的维度过高，使网络的学习难度增加，从而在相同条件下降低了去噪效果。综合考虑各种条件，本文发现在秩为2的情况下，网络展现出了最佳的去噪能力。




图8 不同秩对LR_Unet去噪性能的影响

Fig. 8 The impact of rank settings on the denoising performance of LR_Unet

为了研究不同层数对去噪性能的影响，本文对原始Unet的编码器解码器结构进行了实验，并分别设置了编码/解码器层数为2、3、5进行实验。实验结果如图9所示。从图9中可以看出，在编码/

解码器层数为4时，本文能够取得最佳的去噪结果。




图9 不同编码/解码器层数对LR_Unet去噪性能的影响

Fig. 9 Effect of different coder/decoder layers on the denoising performance of LR_Unet

4 结 论

低秩表示和深度学习是高光谱图像去噪的典型方法在高光谱图像处理领域，低秩表示和深度学习被广泛认为是有效的去噪方法，然而，它们面临的参数确定和物理知识难以利用等问题一直是研究的热点。为处理这些挑战，本文将低秩张量表示与深度神经网络相结合，形成一种新型模型——低秩神经网络，用于高光谱图像去噪。LR_Unet在网络中引入低秩张量分解，精妙地利用高光谱图像的低秩性质，更好地保留图像的重要信息。U-Net的多层编码器—解码器结构在不同尺度上逐步提取高光谱图像的浅层纹理信息和深层结构特征，与低秩张量分解相结合，使得该方法能够综合利用两种方法的优势，克服了传统方法和深度学习在参数确定和物理知识利用方面的限制。实验结果表明LR_Unet具有很强的去噪能力。未来研究可深入挖掘该网络的性能，结合高光谱数据的其他物理先验知识，探索其在相关领域的潜在应用，以提高高光谱图像处理的精度和效率。

参考文献(References)

Chang Y, L Yan and S Zhong. 2017. Hyper-Laplacian Regularized Unidirectional Low-Rank Tensor Recovery for Multispectral Image Denoising. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [10.1109/CVPR.2017.625]

Çiçek Ö, A Abdulkadir, S S Lienkamp, T Brox and O Ronneberger. 2016. 3D U-Net: learning dense volumetric segmentation from

- sparse annotation. International conference on medical image computing and computer-assisted intervention, Springer
- Dong W, H Wang, F Wu, G Shi and X J I T o C I Li. 2019. Deep spatial-spectral representation learning for hyperspectral image denoising. 5(4): 635-648. [10.1109/TCI.2019.2911881]
- Fu Y, A Lam, I Sato and Y Sato. 2015. Adaptive Spatial-Spectral Dictionary Learning for Hyperspectral Image Denoising. 2015 IEEE International Conference on Computer Vision (ICCV): 343-351. [10.1109/iccv.2015.47]
- Guo X, X Huang, L Zhang and L Zhang. 2013. Hyperspectral image noise reduction based on rank-1 tensor decomposition. ISPRS Journal of Photogrammetry and Remote Sensing 83: 50-63. [10.1016/j.isprsjprs.2013.06.001]
- Liu X, S Bourennane and C Fossati. 2012. Denoising of Hyperspectral Images Using the PARAFAC Model and Statistical Performance Analysis. IEEE Trans. Geosci. Remote. Sens. 50(10): 3717-3724. [10.1109/TGRS.2012.2187063]
- Lone Z A and A R Pais. 2022. Object detection in hyperspectral images. Digit. Signal Process. 131: 103752. [10.1016/j.dsp.2022.103752]
- Maggioni M, V Katkovnik, K O Egiazarian and A J I T o I P Foi. 2013. Nonlocal Transform-Domain Filter for Volumetric Data Denoising and Reconstruction.
- Peng J, W Sun, H-C Li, W Li, X Meng, C Ge and Q Du. 2022. Low-Rank and Sparse Representation for Hyperspectral Image Processing: A review. IEEE Geoscience and Remote Sensing Magazine 10(1): 10-43. [10.1109/mgrs.2021.3075491]
- Peng Y, D Meng, Z Xu, C Gao, Y Yang and B Zhang. 2014. Decomposable Nonlocal Tensor Dictionary Learning for Multispectral Image Denoising. 2014 IEEE Conference on Computer Vision and Pattern Recognition. [10.1109/CVPR.2014.377]
- Ronneberger O, P Fischer and T Brox. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation: 234-241. [10.1007/978-3-319-24574-4_28]
- Wu C Z, Chen X and Zhan S. 2020. Remote sensing image denoising using residual encoder-decoder networks with edge enhancement. Journal of Remote Sensing (Chinese), 24(1): 27-36 (吴从中, 陈曦和詹曙. 2020. 结合残差编解码网络和边缘增强的遥感图像去噪. 遥感学报. 24(01): 27-36) [DOI:10.11834/jrs.20208169]
- Wang L, L Wang, Q Wang and L Bruzzone. 2022. RSCNet: A Residual Self-Calibrated Network for Hyperspectral Image Change Detection. IEEE Transactions on Geoscience and Remote Sensing 60: 1-17. [10.1109/TGRS.2022.3177478]
- Wang M, J Yu, J-H Xue and W Sun. 2016. Denoising of Hyperspectral Images Using Group Low-Rank Representation. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 9(9): 4420-4427. [10.1109/jstars.2016.2531178]
- Wei K, Y Fu and H Huang. 2021. 3-D Quasi-Recurrent Neural Network for Hyperspectral Image Denoising. IEEE Trans. Neural Networks Learn. Syst. 32(1): 363-375. [10.1109/TNNLS.2020.2978756]
- Xiong F, J Zhou, S Tao, J Lu, J Zhou and Y Qian. 2022. SMDS-Net: Model Guided Spectral-Spatial Network for Hyperspectral Image Denoising. IEEE Transactions on Image Processing 31: 5469-5483. [10.1109/tip.2022.3196826]
- Xiong F, J Zhou, Q Zhao, J Lu and Y Qian. 2022. MAC-Net: Model-Aided Nonlocal Neural Network for Hyperspectral Image Denoising. IEEE Transactions on Geoscience and Remote Sensing 60: 1-14. [10.1109/TGRS.2021.3131878]
- Xue J, Y Zhao, W Liao and J C-W Chan. 2019. Nonlocal Low-Rank Regularized Tensor Decomposition for Hyperspectral Image Denoising. IEEE Trans. Geosci. Remote. Sens. 57(7): 5174-5189. [10.1109/TGRS.2019.2897316]
- Ye M, Y Qian and J Zhou. 2015. Multitask Sparse Nonnegative Matrix Factorization for Joint Spectral - Spatial Hyperspectral Imagery Denoising. IEEE Transactions on Geoscience and Remote Sensing 53(5): 2621-2639. [10.1109/tgrs.2014.2363101]
- Zhang H, W He, L Zhang, H Shen and Q Yuan. 2014. Hyperspectral Image Restoration Using Low-Rank Matrix Recovery. IEEE Trans. Geosci. Remote. Sens. 52(8): 4729-4743. [10.1109/TGRS.2013.2284280]
- Zhang K, W Zuo, Y Chen, D Meng and L Zhang. 2017. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. IEEE Trans Image Process 26(7): 3142-3155. [10.1109/TIP.2017.2662206]
- Zhang S, L Wang, L Zhang and H Huang. 2021. Learning Tensor Low-Rank Prior for Hyperspectral Image Reconstruction. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). [10.1109/CVPR46437.2021.01183]
- Zheng Y-B, T-Z Huang, X-L Zhao, T-X Jiang, T-H Ma and T-Y Ji. 2020. Mixed Noise Removal in Hyperspectral Image via Low-Fibered-Rank Regularization. IEEE Trans. Geosci. Remote. Sens. 58(1): 734-749. [10.1109/TGRS.2019.2940534]
- Zhu Q, W Deng, Z Zheng, Y Zhong, Q Guan, W Lin, L Zhang and D Li. 2022. A Spectral-Spatial-Dependent Global Learning Framework for Insufficient and Imbalanced Hyperspectral Image Classification. IEEE Transactions on Cybernetics 52(11): 11709-11723. [10.1109/TCYB.2021.3070577]
- Zhuang L and J M Bioucas-Dias. 2018. Fast Hyperspectral Image Denoising and Inpainting Based on Low-Rank and Sparse Representations. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 11(3): 730-742. [10.1109/jstars.2018.2796570]

Low-rank tensor embedded deep neural network for hyperspectral image denoising

TU Kun¹, XIONG Fengchao¹, HOU Xueqiang²

1. School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, China;

2. Jiuquan Satellite Launch Center, Jiuquan 732750, China

Abstract: Spectral imagery has emerged as a powerful tool with widespread applications across various fields. This tool's unique ability to identify materials continuous narrow bands has made it invaluable for tasks such as environmental monitoring, resource management, and agricultural early warning. However, the hyperspectral imagery utility is often compromised by the presence of noise from factors such as equipment errors and atmospheric conditions. This noise poses a significant challenge to the accuracy of subsequent analytical tasks, requiring the development of effective hyperspectral image denoising techniques. The spatial, spectral, and spatial-spectral joint correlations observed in hyperspectral images indicate that clean hyperspectral images occupy a low-dimensional subspace. This characteristic can be effectively characterized by low-rank and sparse representations. Consequently, a considerable body of research has been dedicated to exploring denoising methods based on such representations to enhance hyperspectral image quality. On the one hand, while deep learning methods offer the advantage of directly extracting prior information from data, they often exhibit low efficiency in the utilization of physical knowledge specific to hyperspectral images, such as their inherent low-rank nature. On the other hand, model-based techniques require the manual setting of priors and intricate parameter tuning, presenting a challenge in terms of practicality and adaptability. The objective of this study is to address the existing challenges in hyperspectral image denoising by proposing a novel approach that combines the strengths of deep learning- and model-based methods. The proposed methodology leverages the spatial-spectral low-rank characteristics inherent in hyperspectral images and embeds the low-rank tensor decomposition module into the U-Net for enhanced denoising. The low-rank tensor decomposition module is based on CP decomposition, generates rank-one vectors, and reconstructs low-rank tensors through operations like global pooling and convolution. The low-rank tensor decomposition module is integrated with the U-net architecture to represent shallow features as low-rank tensors. This strategy enables the model to capture spatial-spectral low-rank characteristics comprehensively, thereby significantly enhancing its denoising capabilities. Experimental evaluations, encompassing both simulated and real data, validate the efficacy of the proposed low-rank deep neural network method. Across a noise standard deviation range of [0—95], the algorithm achieves a peak signal-to-noise ratio of 41.02 dB and a structural similarity index of 0.9888. Empirical results underscore the superiority of the proposed low-rank deep neural network method over alternative approaches in terms of denoising performance for hyperspectral images. By effectively leveraging the spatial-spectral low-rank characteristics intrinsic to hyperspectral images, this methodology presents a robust solution for enhancing the accuracy of hyperspectral imagery in diverse applications. The amalgamation of low-rank tensor decomposition with deep learning techniques not only addresses existing challenges but also opens up promising avenues for future research in hyperspectral image processing, paving the way for improved methodologies and innovative solutions. The comprehensive exploration of this combined approach provides valuable insights and contributes to the evolving landscape of hyperspectral image analysis and enhancement.

Key words: hyperspectral image denoising, deep neural network, low-rank tensor representation, knowledge-driven deep learning, CP decomposition, U-Net

Supported by National Natural Science Foundation of China (No. 62002169)