

基于卷积神经网络的端到端多光谱图像压缩方法

孔繁锵¹, 周永波^{1*}, 沈秋², 温珂瑶¹

¹南京航空航天大学航天学院, 江苏 南京 210000;

²南京大学电子科学与工程学院, 江苏 南京 210046

摘要 针对多光谱图像的空谱相关特性, 提出一种基于卷积神经网络的端到端多光谱图像压缩方法。编码端, 将多光谱数据整体输入到多光谱图像压缩网络中, 采用卷积提取多光谱图像的主要光谱特征与空间特征, 使用下采样减小特征数据的尺寸, 并通过率失真优化控制光谱特征与空间特征数据的熵, 使空谱特征数据分布更加紧凑, 将量化后的中间特征数据进行无损熵编码得到压缩码流。解码端, 码流经过熵解码、逆量化、上采样、反卷积的逆变换过程重构多光谱图像。实验结果表明, 相同码率下该方法能有效保留多光谱图像谱间信息, 并在图像恢复质量上比 JPEG2000 平均高约 2 dB。

关键词 图像处理; 深度学习; 多光谱图像压缩; 卷积神经网络; 率失真优化

中图分类号 TP751

文献标识码 A

doi: 10.3788/CJL201946.1009001

End-to-End Multispectral Image Compression Using Convolutional Neural Network

Kong Fanqiang¹, Zhou Yongbo^{1*}, Shen Qiu², Wen Keyao¹

¹College of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 210000, China;

²School of Electronic Science and Engineering, Nanjing University, Nanjing, Jiangsu 210046, China

Abstract Aiming at the spatial-spectral correlation characteristics of multispectral images, we propose an end-to-end multispectral image compression method using a convolutional neural network. At the encoding end, multispectral data are fed into the multispectral image compression network, and the main spectral and spatial features of the multispectral image are extracted using convolution. The size of the feature data is reduced by downsampling. The entropy of the spatial-spectral feature data is controlled by the rate distortion, and a dense distribution of spatial-spectral feature data is obtained. The intermediate feature data are quantized and encoded using lossless entropy coding to obtain a compressed bitstream. At the decoding end, the bitstream can be used to reconstruct the multispectral image through an inverse transformation process that involves entropy coding, inverse quantization, upsampling, and deconvolution. Experimental results denote that the proposed method can effectively preserve the spectral information contained in the multispectral images at the same bit rate and improve image reconstruction quality by 2 dB than that of JPEG2000.

Key words image processing; deep learning; multispectral image compression; convolutional neural network; rate distortion optimization

OCIS codes 100.3020; 100.6890; 110.4234

1 引 言

多光谱图像既包含地表图像的空间信息, 也包含丰富的光谱信息, 多光谱数据经科学、高效地分析处理后, 可以应用于农业、军事^[1]等多个领域。然

而, 多光谱图像特征维度大, 像素点众多, 拥有巨大的数据量, 对其传输和存储带来了巨大的困难, 这严重制约了多光谱成像技术的发展。因此必须对多光谱图像进行有效的压缩, 研究高性能的多光谱图像压缩方法是多光谱成像技术的重要研究课题。多光

收稿日期: 2019-05-22; 修回日期: 2019-06-11; 录用日期: 2019-06-17

基金项目: 国家自然科学基金(61801214)

* E-mail: zybfight@163.com

谱图像的相关性有两个方面:一是空间相关性,即每个波段图像相邻像素间的相关性;二是谱间相关性,即同一空间位置在相邻波段映射成的不同像素之间的相关性。多光谱图像压缩方法不仅要有效去除多光谱图像的空间相关性,还必须能够很好地去除多光谱图像的谱间相关性。

传统的多光谱图像压缩算法主要分为三类:1)基于预测的编码算法^[2],其主要思想是利用像素与其周围像素的空间相关性以及波段与相邻波段之间的谱间相关性来实现多光谱图像的压缩;2)基于矢量量化技术的编码算法^[3],其基本思路是将多光谱图像数据分解为一个矢量的集合,然后对矢量集合里的每一个矢量进行量化编码;3)基于变换的编码算法^[4-5],通过变换将多光谱图像从空间域变换到频域,而频域内图像的能量比较集中,便于进一步地压缩编码。这三类算法都存在明显的不足,基于矢量量化技术的编码算法复杂度极高,很难实现无损压缩;基于预测的编码算法虽然能实现无损压缩,但是压缩率较低;而基于变换的编码算法在压缩率较大时,会出现方块效应和边缘吉布斯效应,这些方法未能充分利用多光谱数据的特点。

最近的研究表明,将深度学习运用于有损图像压缩中具有很大的潜力^[6-9]。这些方法利用自编码器或堆叠自编码器在中间层生成特征映射,用于后续的量化和熵编码,量化引起的误差或失真将用于端到端优化。对于可见光图像压缩,Toderici等^[6-7]利用循环神经网络(RNN)逐步生成熵编码的比特流,生成不同质量的中间层重构图像,网络通过控制迭代次数控制图像的压缩比。对于全息图像压缩,Jiao等^[10]利用卷积神经网络(CNN)减少联合图像专家组图像压缩标准(JPEG)压缩全息图像产生的伪影,解决了压缩过程中因丢失某些高频特征而造成的图像质量退化。对于光场图像压缩,Bakir等^[11]在解码端利用深度学习(DL)将从编码端得到的稀疏图像重构为光场图像。上述方法在客观和主观上都优于JPEG^[12]和基于小波变换的图像压缩标准(JPEG2000^[13])的编码效果。

多光谱图像数据是三维数据立方,且各谱段图像之间没有运动位移,是三维静止图像。所以多光谱图像编码方法可以在二维静止图像编码方法的基础上发展而来。本文针对多光谱图像的空谱相关特性,结合深度学习,提出一种基于CNN的端到端有损多光谱图像压缩方法,整体结构由正向编码网络、量化器、反向解码网络、率失真(RD)优化组成。该算法在编

码端,基于CNN并采用下采样处理、率失真优化、无损熵编码对图像多光谱特征数据进行压缩,并得到用于存储和传输的码流;在解码端,码流经过熵解码、逆量化、上采样、反卷积的逆变换过程重构多光谱图像。为验证本文压缩算法的性能,从图像客观质量评价和光谱信息损失评价两方面与JPEG和JPEG2000算法进行比较,结果表明,在相同码率的情况下,该方法能有效保留多光谱图像谱间信息。

2 端到端的多光谱图像压缩网络结构

提出的端到端多光谱图像压缩网络结构如图1所示。多光谱图像经过前向编码网络,通过卷积层将图像信息转换至特征空间,提取出多光谱图像的主要光谱特征与空间特征,然后利用下采样减小光谱特征与空间特征数据的尺寸,多光谱图像的数据量显著降低,得到初步的压缩,再经过量化处理继续压缩多光谱图像的数据量,将量化后的空谱特征数据进行无损熵编码(本文采用一种高压缩比图像压缩标准ZPAQ^[14]的无损压缩方法)得到压缩码流。解码端与编码端具有对称的结构,解码时,先将得到的码流通过熵解码还原为空谱特征数据,还原后的空谱特征数据经过逆量化层、反卷积层和上采样层,逐步恢复为原始多光谱图像的维度与尺寸,将图像从特征空间恢复到像素空间。其中,通过率失真优化可以显式地控制空谱特征数据的熵,得到分布更紧凑的空谱特征数据,能有效地提高无损熵编码的压缩效果,进一步提升压缩性能。

输入的多光谱图像经过CNN提取得到48通道的中间特征图像如图2所示。图中ah-chun23与hunan-qiu233为两个多光谱原始图像(第7个波段),fMap_5、fMap_16、fMap_32、fMap_46分别代表多光谱中间特征图像的第5、16、32、46波段的图像。可以看到,中间特征图像保留了多光谱图像的主要特征信息(如地物、边缘、纹理信息等),并且通过三次下采样,中间特征图像的尺寸降低为原始多光谱图像的1/64,在保留主要信息的同时有效地减小了图像的数据量,这对后续的无损熵编码及图像恢复具有重要的意义。

2.1 前向编码网络与反向解码网络

提出的多光谱图像压缩网络使用残差网络(ResNet)^[15]作为基本单元结构,这是因为ResNet具有更高的效率和更快的收敛速度。为了使网络进一步获得更好的收敛速度,如图3所示,将默认的线性整流函数(ReLU)^[16]替换为参数化线性修正单元

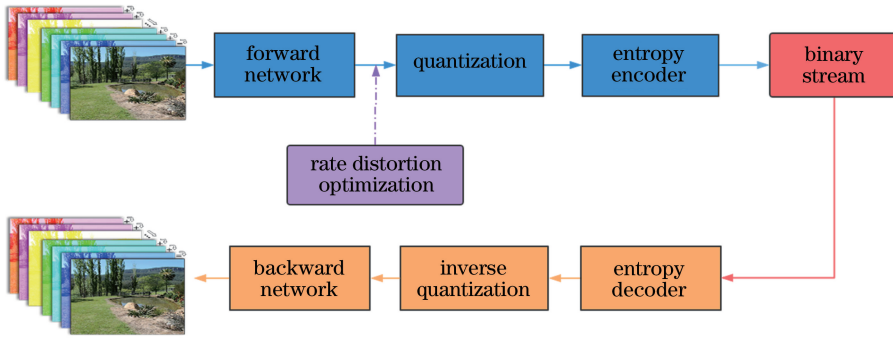


图 1 压缩网络整体流程图

Fig. 1 Overall flow chart of compression network




图 2 中间特征图像可视化。(a)原始图像;(b) fMap_5;(c) fMap_16;(d) fMap_32;(e) fMap_46

Fig. 2 Intermediate feature image visualization. (a) Original image; (b) fMap_5; (c) fMap_16; (d) fMap_32; (e) fMap_46

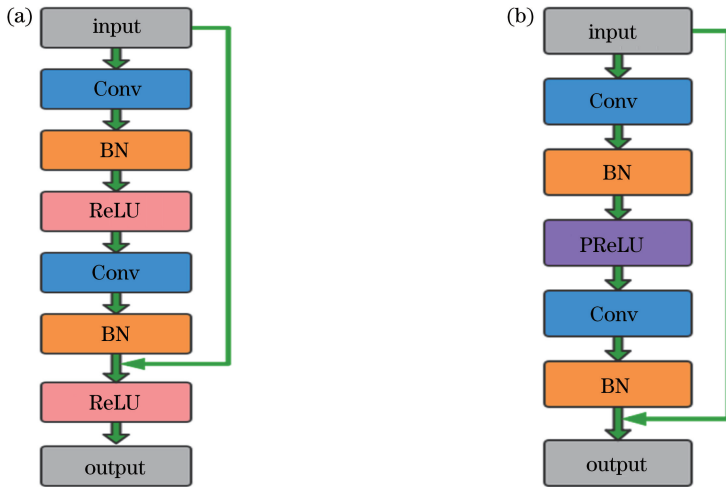


图 3 残差网络单元架构。(a) ResNet 中的默认架构;(b) 本文替换 ReLU 后的架构 ResUnit

Fig. 3 Illustrations of residual network unit. (a) Default architecture in ResNet;

(b) proposed architecture ResUnit by replacing ReLU

(PReLU)^[17], 并且去掉了输出端的一层 ReLU。图 3 中, Conv 代表卷积层, BN 代表批标准化层。

前向编码网络用于提取输入多光谱图像的中间特征图像, 保留多光谱图像的主要光谱信息与空间信息, 有助于更精确地重建高质量图像。反向解码

网络用于将中间特征图像重构为多光谱图像。将这两个网络作为一个整体进行训练得到端到端的多光谱图像压缩网络。对于多光谱图像, 只需要将其三维数据整体输入到压缩网络, 不需要进行预处理即可得到压缩后的码流。如图 4(a) 所示, 前向编码器

网络包含 7 个残差单元(ResUnit), 3 次下采样处理(DownSampling), 残差单元结构如图 3(b)所示, 所有下采样操作都使用步长为 2 的 4×4 卷积层, 最后经过 Sigmoid 函数层得到中间特征图像。如图 4(b)所示, 反向解码网络与前向解码网络具有对称

的结构, 通过中间特征图像重构输入图像。本研究采用 pixelShuffle^[18] 作为上采样(UpSampling)操作, 该方法已经在超分辨率领域被证实具有良好的性能。所有卷积层除第一层和最后一层的卷积核为 5×5 外, 其余均为 3×3 内核大小。

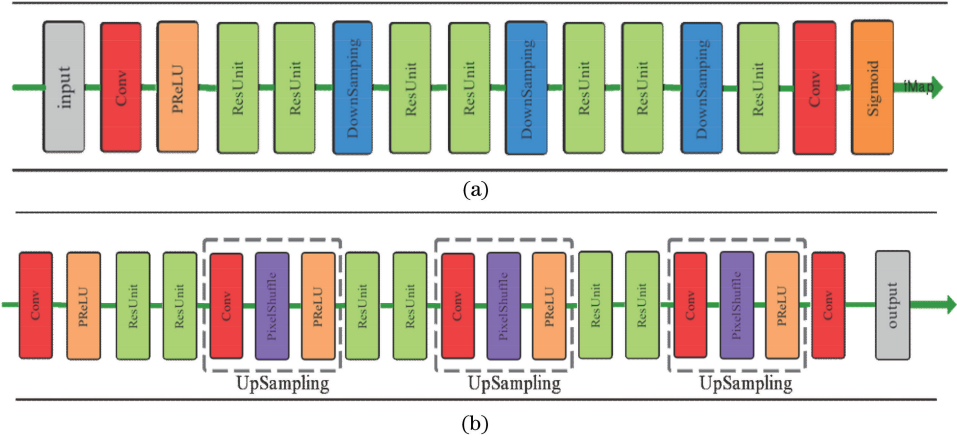


图 4 压缩网络主要架构。(a)前向编码网络架构;(b)反向解码网络架构

Fig. 4 Illustrations of compression networks. (a) Forward coding network architecture; (b) reverse decoding network architecture

2.2 量化层与熵编码

经前向压缩网络提取得到的中间特征数据为浮点数, 需对其进行量化处理。根据文献[6], 量化函数的导数几乎处处为 0, 直接加入到网络中, 在反向传播时会出现梯度消失的情况, 因此需要对量化函数进行一些近似处理, 公式如下

$$X_Q = \text{Round}[(2^Q - 1) \times \text{Sigmoid}(X_E)], \quad (1)$$

式中: Round[·] 将数据进行四舍五入处理; Sigmoid(·) 将变量映射到 (0, 1) 之间; X_Q 为量化后的中间特征数据; X_E 为经过卷积层提取的中间特征数据; Q 为量化级。

近似处理过的量化函数, 正向传播时将数据四舍五入, 反向传播时则跳过量化层, 将梯度传递给前一层。然后对量化过的中间特征数据 X_Q 采用 ZPAQ 无损压缩生成二进制码流。对码流进行熵解码还原得到量化后的中间特征数据 X_Q , 之后将逆量化后的中间特征数据 $X_Q / (2^Q - 1)$ 输入到反向解码网络中。

2.3 率失真优化

为了进一步优化多光谱压缩网络的性能, 尽可能地减小码率, 同时尽可能地保持恢复图像的质量, 需要在码率和图像质量损失之间进行权衡, 本研究采取的损失函数为

$$L = L_d + \lambda L_e, \quad (2)$$

式中: L 为整个网络的损失值; L_d 为失真度, 本研究采用的是均方误差; λ 是惩罚权重; L_e 是量化后特征图数据的熵近似。通过训练不断降低 L_d 的值,

使恢复图像的像素值越来越接近原图像的像素值, 从而保证图像恢复质量, 同时通过训练不断降低 L_e 的值, 使中间特征图数据分布更加紧凑, 有效提高了后续无损熵编码的压缩效率, 提高压缩性能。

L_d 的计算公式为

$$L_d = \frac{1}{N} \sum_{n=1}^N \| (\mathbf{Y}_n | \theta) - \mathbf{X}_n \|^2, \quad (3)$$

式中: \mathbf{X}_n 表示输入图像; \mathbf{Y}_n 表示压缩网络恢复图像; n 为第 n 幅多光谱图像; N 表示批尺寸; θ 表示压缩网络的参数。

熵的计算公式为

$$L_e = -E[\text{lb } P_q(x)], \quad (4)$$

$$P_q(x) = \int_{x-\frac{1}{2}}^{x+\frac{1}{2}} P_d(x) dx, \quad (5)$$

式中: E 表示求期望; x 为像素点的数值; $P_q(x)$ 为像素点为 x 的概率; $P_d(x)$ 为数据的概率密度函数。

将中间特征数据的熵引入到损失函数中, 可以让网络在学习的过程中不断优化中间特征数据的熵, 进而提高网络的压缩性能, 但是熵的计算需要统计数据的分布, 而这个分布是离散的, 若直接加入网络, 会导致无法对反向更新网络参数进行求导。因此, 需要用一个连续可导的函数 L_e 去近似替代 L_e 。量化后的中间特征数据均为整数, 其数据分布是离散的, 先对每个整数间隔进行采样, 采样点越多, 熵估计的精度就越高; 然后对相邻离散点之间没有值的区域进行插值处理(本文采用的是样条插值^[8]),

得到连续的数据分布,其概率密度函数为 $P_c(x)$, L_c 的计算公式表示为

$$L_c = -E \left[\ln \left(\int_{x-\frac{1}{2}}^{x+\frac{1}{2}} P_c(x) dx \right) \right]. \quad (6)$$

3 优化网络参数

多光谱图像压缩网络的目标是尽可能使恢复图像还原输入图像,保留原始图像信息,在网络中表现为,通过学习与训练获取最优的网络参数使损失函数数值最小,其公式表示为

$$\begin{aligned} & (\hat{\theta}_1, \hat{\theta}_2) = \\ & \arg \min_{\theta_1, \theta_2} \| \text{De}\{\theta_2, \text{Qu}[\text{En}(\theta_1, \mathbf{x}_n)]\} - \mathbf{x}_n \|^2, \end{aligned} \quad (7)$$

式中: $\hat{\theta}_1$ 为前向编码网络的最优参数; $\hat{\theta}_2$ 为反向解码网络的最优参数; \mathbf{x}_n 为输入图像; θ_1 为前向编码网络的参数; θ_2 为反向解码网络的参数; $\text{Qu}(\cdot)$ 表示量化处理; $\text{En}(\cdot)$ 和 $\text{De}(\cdot)$ 分别表示前向编码网络和反向解码网络。

为使损失函数最快地到达最小值点,将参数 θ_1, θ_2 沿梯度下降的方向变化。固定 θ_2 , 可以得到

$$\hat{\theta}_1 = \arg \min_{\theta_1} \| \text{De}\{\hat{\theta}_2, \text{Qu}[\text{En}(\theta_1, \mathbf{x}_n)]\} - \mathbf{x}_n \|^2, \quad (8)$$

固定 θ_1 , 可以得到

$$\hat{\theta}_2 = \arg \min_{\theta_2} \| \text{De}\{\theta_2, \text{Qu}[\text{En}(\hat{\theta}_1, \mathbf{x}_n)]\} - \mathbf{x}_n \|^2. \quad (9)$$

更新反向编码网络的参数:引入辅助变量 $\hat{\mathbf{x}}_m$, 用以表示中间特征图数据,表达式为

$$\hat{\mathbf{x}}_m = \text{Qu}[\text{En}(\hat{\theta}_1, \mathbf{x}_n)], \quad (10)$$

结合(8)式可得

$$\hat{\theta}_2 = \arg \min_{\theta_2} \| \text{De}(\theta_2, \hat{\mathbf{x}}_m) - \mathbf{x}_n \|^2. \quad (11)$$

更新前向编码网络的参数:根据(8)式与(1)式,得到近似处理过的量化函数,反向传播时直接跳过量化层,将梯度传递给前一层,(8)式可变换为

$$\hat{\theta}_1 = \arg \min_{\theta_1} \| \text{De}[\hat{\theta}_2, \text{En}(\theta_1, \mathbf{x}_n)] - \mathbf{x}_n \|^2. \quad (12)$$

4 实验结果与分析

4.1 实验数据集

多光谱图像压缩网络的训练集和测试集来源于 landsat8 卫星的多光谱图像,包含 7 个多光谱波段。

为了防止网络过拟合,网络的训练集选取包含不同时令、多种地形和天气的多光谱图像,具有较为丰富和完备的特征,并将其裁剪为 80000 个 $128 \text{ pixel} \times 128 \text{ pixel}$ 像素块作为训练集。以同样的标准选取得到网络的 24 个测试集,裁剪为 $512 \text{ pixel} \times 512 \text{ pixel}$ 像素块,网络的训练集与测试集不能交叉。

4.2 网络参数设置

网络训练使用 Adam Optimizer^[19],为使网络快速收敛,初始学习率设置为 0.0001,生成预训练模型后逐渐缩小学习率,通过不断训练得到所需要的模型。对于率失真优化,根据 easy-to-hard 的学习思想^[20],在初始阶段 L_c 设置为 0,待网络充分收敛后,逐步增加 L_c 的惩罚权重 λ ,使中间特征图数据的分布逐渐集中,显著地提升压缩性能。这样做可以防止网络迅速收敛到熵值很低的局部最优,而无法充分学习到图像分布的特征。通过改变多光谱图像压缩网络的超参数,可以训练得到不同码率的压缩网络模型,控制压缩网络的码率,具体有两种方式:

1) 固定率失真优化中的惩罚权重 λ ,通过改变中间卷积层神经元的个数,训练得到不同码率的压缩网络,神经元个数越少压缩码率越小;

2) 固定中间卷积层神经元的个数,通过改变率失真优化中的惩罚权重 λ 的大小,训练得到不同码率的压缩网络, λ 越大压缩码率越小。

4.3 实验结果及分析

多光谱图像既包含空间二维信息也包含一维光谱信息,为了验证本文压缩算法的性能,将从图像客观质量评价和光谱信息损失评价两方面与 JPEG 和 JPEG2000 算法进行比较。为了检验压缩前后图像质量的损失情况,引入峰值信噪比 (PSNR, P_{SNR}) 参量作为评价指标,将本文算法与 JPEG 和 JPEG2000 在 8 个码率下进行比较。

图 5 所示为不同码率下测试数据集的平均

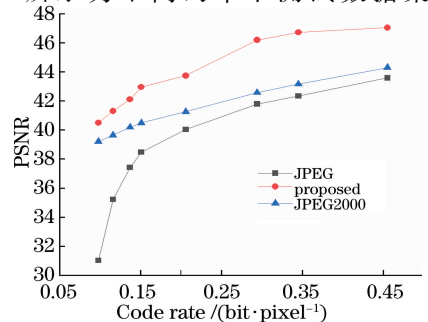


图 5 不同码率下测试数据集的平均 P_{SNR}

Fig. 5 Average P_{SNR} of test dataset at different code rates

P_{SNR} ,图 6 (a) ~ (d) 分别为 tj-chun118、hunan-qiu233、ss443、tj-xia216 共 4 张多光谱图像的测试结果。从图中的对比结果可以看到,JPEG2000 在测试的 8 个码率下的 P_{SNR} 均优于 JPEG,而本文算

法不论是在低码率还是高码率,其 P_{SNR} 均高于 JPEG 和 JPEG2000,比 JPEG2000 平均高约 2 dB。在低码率时,JPEG 算法的 P_{SNR} 下降显著,而本文算法随着码率降低, P_{SNR} 下降相对缓慢。

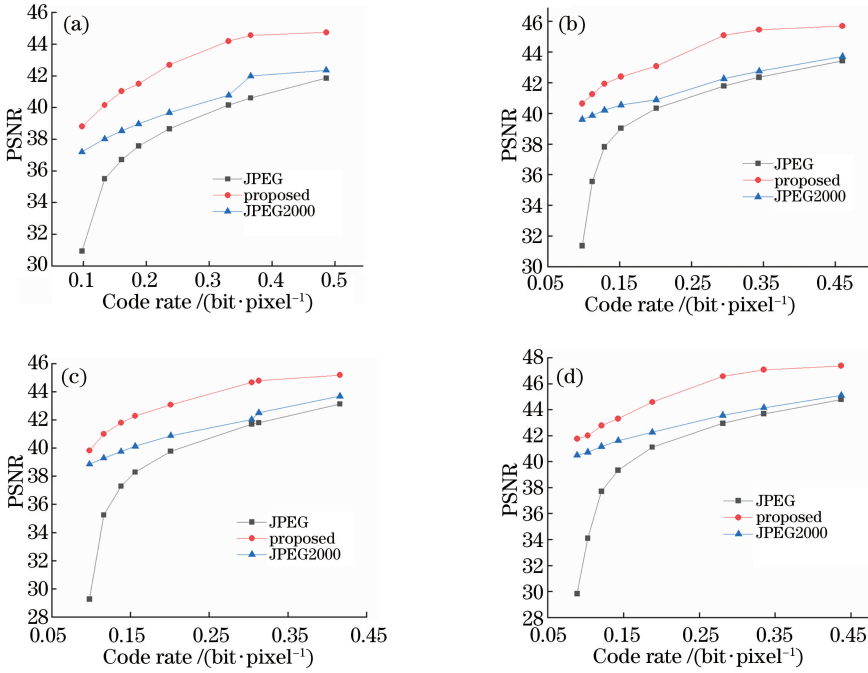


图 6 RD 曲线。(a) tj-chun118;(b) hunan-qiu233;(c) ss443;(d) tj-xia216

Fig. 6 RD curves. (a) tj-chun118; (b) hunan-qiu233; (c) ss443; (d) tj-xia216

为了更直观地比较本文算法与 JPEG 和 JPEG2000 算法,将三种算法恢复得到的多光谱图像的每个谱段分别进行比较。图 7(a)~(d) 依次为上述 4 张测试图像第 7 谱段的图像展示(为更清晰全面地反映图像的信息,使用 MATLAB 中 colorbar 的 jet 模式显示图像),4 栏中从左往右依次是原始未压缩图像、JPEG 压缩恢复图像、JPEG2000 压缩恢复图像以及本文算法的压缩恢复图像。比较几幅图像发现,JPEG 和 JPEG2000 算法恢复图像均存在很明显的块效应与环效应,整体轮廓及细节纹理比较模糊,而本文算法恢复的图像保留了更多的细节纹理和边缘特征,更接近于原图像。

为了更好地检验压缩前后光谱信息的损失情况,引入光谱曲线相似度 S_{SS} ^[21] 参量作为指标来评价压缩前后光谱曲线的变化,其定义为

$$S_{SS} = \sqrt{E_{RMSE_{w,h}}^2 + (1 - C_{Corrw,h}^2)^2}, \quad (13)$$

式中: S_{SS} 为光谱曲线相似度; w 为行数; h 为列数; $E_{RMSE_{w,h}}$ 为重构多光谱图像第 w 行第 h 列像素点与原始多光谱图像第 w 行第 h 列像素点的均方根误差; $C_{Corrw,h}$ 为重构多光谱图像第 w 行第 h 列像素点

与原始多光谱图像第 w 行第 h 列像素点的相关系数。 $E_{RMSE_{w,h}}$ 和 $C_{Corrw,h}$ 的计算公式分别为

$$E_{RMSE_{w,h}}^2 = \frac{1}{mc} \sum_c [f(w,h,c) - \tilde{f}(w,h,c)]^2, \quad (14)$$

$$C_{Corrw,h} = \frac{\sum_c [I(w,h,c) - \tilde{I}(w,h,c)]^2}{(mc-1)\delta(w,h,\cdot)\tilde{\delta}(w,h,\cdot)}, \quad (15)$$

$$I(w,h,c) = f(w,h,c) - E(w,h,\cdot), \quad (16)$$

$$\tilde{I}(w,h,c) = \tilde{f}(w,h,c) - \tilde{E}(w,h,\cdot), \quad (17)$$

式中: m 为选取像素点个数; $f(w,h,c)$ 为原始多光谱图像第 c 谱段第 w 行第 h 列像素值; $\tilde{f}(w,h,c)$ 为重构多光谱图像第 c 谱段第 w 行第 h 列像素值; $I(w,h,c)$ 为原始多光谱图像第 c 谱段第 w 行第 h 列像素点减去第 w 行第 h 列所有谱段像素点均值后的值; $\tilde{I}(w,h,c)$ 为重构多光谱图像第 c 谱段第 w 行第 h 列像素点减去第 w 行第 h 列所有谱段像素点均值后的值; $E(w,h,\cdot)$ 和 $\delta(w,h,\cdot)$ 分别为原始多光谱图像中单点像素光谱的均值和方差; $\tilde{E}(w,h,\cdot)$ 和 $\tilde{\delta}(w,h,\cdot)$ 为重构多光谱图像单点像素光谱的均值和方差。

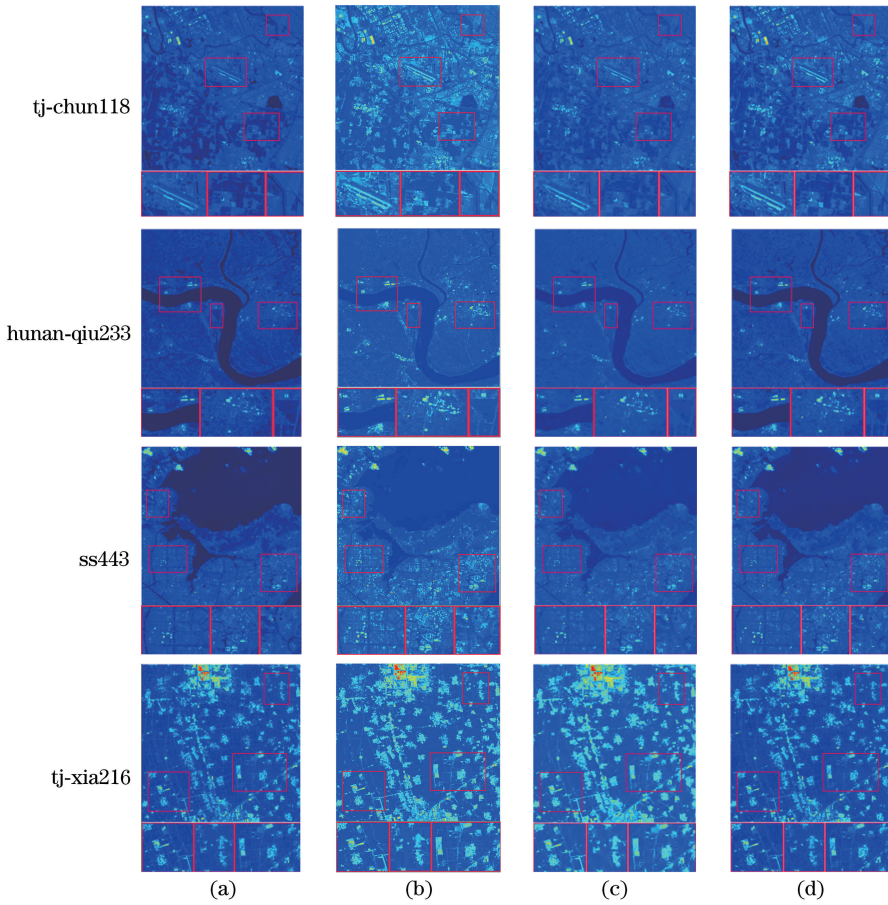


图 7 恢复图像展示。(a)原始图像;(b) JPEG;(c) JPEG2000;(d)本文算法

Fig. 7 Reconstructed image display. (a) Original image; (b) JPEG; (c) JPEG2000; (d) proposed algorithm




图 8 光谱相似度曲线

Fig. 8 Spectral similarity curves

为了有效地反映全部光谱的恢复效果,从恢复的多光谱图像 tj-xia216 中取连续 100 个像素点,比较本文算法与 JPEG 和 JPEG2000 的光谱相似度曲线,结果如图 8 所示。表 1 为测试数据集在不同码率下的平均光谱相似度,即不同码率下所有测试多光谱图像连续 100 个像素点的平均光谱相似度的均

值。可以看到,通过多光谱图像压缩网络得到的 100 个连续像素点的光谱相似度曲线一直保持在 JPEG 和 JPEG2000 光谱相似度曲线的下方,不同码率下多光谱图像压缩网络的平均光谱相似度小于 JPEG 和 JPEG2000 的平均光谱相似度。光谱相似度值越小,说明光谱曲线越相似,越接近原光谱。整

表 1 不同码率下测试数据集的平均光谱相似度
Table 1 Average spectral similarity of test dataset at different code rates

Test dataset	Code rate / (bit•pixel ⁻¹)							
	0.098	0.116	0.137	0.151	0.206	0.294	0.345	0.455
JPEG	1429.560	1230.880	616.868	445.511	283.592	269.364	187.519	164.105
JPEG2000	396.171	312.923	282.149	271.791	260.262	248.623	154.931	149.086
Proposed	189.911	185.021	178.488	174.609	157.862	149.392	109.811	93.105

体的实验数据表明,本文算法在光谱相似度曲线上较 JPEG 和 JPEG2000 具有更好的性能,更有效地保留了光谱信息。

5 结 论

提出了基于 CNN 的端到端有损多光谱图像压缩方法,该算法通过多层卷积得到多光谱图像的主要光谱特征与空间特征,结合现有的压缩编码方法进行处理,加入率失真优化可以显式地控制中间特征图的熵,得到分布更紧凑的中间特征图数据,进一步提高压缩性能。实验结果表明,提出的压缩算法优于 JPEG 和 JPEG2000,在相同码率的情况下,提出的算法有效地保留了光谱信息和更多的空间信息。由此表明将深度学习与多光谱图像压缩相结合的方法具有巨大的潜力。

参 考 文 献

[1] Luo M, Bu Y, Xu J H, *et al.* Optical element surface defect measurement based on multispectral technique[J]. Chinese Journal of Lasers, 2017, 44 (1): 0104001.
罗茂, 步扬, 徐静浩, 等. 基于多光谱技术的光学元件表面疵病检测[J]. 中国激光, 2017, 44 (1): 0104001.

[2] Gelli G, Poggi G. Compression of multispectral images by spectral classification and transform coding [J]. IEEE Transactions on Image Processing, 1999, 8(4): 476-489.

[3] Zhou Z L. Research on hyperspectral image compression method [D]. Nanjing: Nanjing University of Science and Technology, 2008.
周志林. 高光谱图像压缩方法研究[D]. 南京: 南京理工大学, 2008.

[4] Li Y S, Wu C K, Chen J, *et al.* Spectral satellite image compression based on wavelet transform [J]. Acta Optica Sinica, 2001, 21(6): 691-695.
李云松, 吴成柯, 陈军, 等. 基于小波的干涉多光谱卫星图像压缩方法[J]. 光学学报, 2001, 21(6): 691-695.

[5] Luigi Dragotti P, Poggi G, Ragozini A R P. Compression of multispectral images by three-

dimensional SPIHT algorithm [J]. IEEE Transactions on Geoscience and Remote Sensing, 2000, 38(1): 416-428.

[6] Toderici G, O' Malley S M, Hwang S J, *et al.* Variable rate image compression with recurrent neural networks[J/OL]. (2016-03-01)[2019-05-01]. <https://arxiv.org/abs/1511.06085>.

[7] Toderici G, Vincent D, Johnston N, *et al.* Full resolution image compression with recurrent neural networks[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE, 2017: 5435-5443.

[8] Ballé J, Laparra V, Simoncelli E P. End-to-end optimized image compression[J/OL]. (2017-03-03) [2019-05-01]. <https://arxiv.org/abs/1611.01704>.

[9] Rippel O, Bourdev L. Real-time adaptive image compression[C] // 34th International Conference on Machine Learning, August 6-11, 2017, Sydney, Australia. Massachusetts: JMLR. org, 2017, 70: 2922-2930.

[10] Jiao S M, Jin Z, Chang C L, *et al.* Compression of phase-only holograms with JPEG standard and deep learning[J]. Applied Sciences, 2018, 8(8): 1258.

[11] Bakir N, Hamidouche W, Deforges O, *et al.* Light field image compression based on convolutional neural networks and linear approximation [C] // 2018 25th IEEE International Conference on Image Processing (ICIP), October 7-10, 2018, Athens. New York: IEEE, 2018: 1128-1132.

[12] Wallace G K. The JPEG still picture compression standard[J]. Communications of the ACM, 1991, 34 (4): 30-44.

[13] Lee D T. JPEG 2000: retrospective and new developments[J]. Proceedings of the IEEE, 2005, 93 (1): 32-41.

[14] Mahoney M. The ZPAQ open standard format for highly compressed data-level 2[J/OL]. (2014-11-18) [2019-05-02]. <http://mattmahoney.net/dc/zpaq204.pdf>.

[15] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas,

- NV, USA. New York: IEEE, 2016: 770-778.
- [16] Hara K, Saito D, Shouno H. Analysis of function of rectified linear unit used in deep learning [C] // 2015 International Joint Conference on Neural Networks (IJCNN), July 12-17, 2015, Killarney, Ireland. New York: IEEE, 2015: 7280578.
- [17] He K M, Zhang X Y, Ren S Q, *et al.* Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 1026-1034.
- [18] Shi W Z, Caballero J, Huszar F, *et al.* Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 1874-1883.
- [19] Kingma D, Ba J. Adam: a method for stochastic optimization [J/OL]. (2017-01-30) [2019-05-02]. <https://arxiv.org/abs/1412.6980>.
- [20] Dong C, Deng Y B, Loy C C, *et al.* Compression artifacts reduction by a deep convolutional network [C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 576-584.
- [21] Li Y S, Kong F Q, Wu C K, *et al.* Interference multi-spectral image compression based on distributed source coding [J]. Acta Optica Sinica, 2008, 28(8): 1463-1468.
- 李云松, 孔繁镛, 吴成柯, 等. 基于分布式信源编码的干涉多光谱图像压缩 [J]. 光学学报, 2008, 28(8): 1463-1468.