

基于自适应波段聚类主成分分析和反向传播神经网络的高光谱图像压缩

陈善学 张燕琪*

^①(重庆邮电大学通信与信息工程学院 重庆 400065)

^②(重庆邮电大学移动通信技术重庆市重点实验室 重庆 400065)

摘要: 高光谱遥感图像具有丰富的光谱信息, 数据量大。为了能够有效地利用高光谱图像数据, 促进高光谱遥感技术的发展, 该文提出一种基于自适应波段聚类主成分分析(PCA)与反向传播(BP)神经网络相结合的高光谱图像压缩算法。算法利用近邻传播(AP)聚类算法对波段进行自适应聚类, 对聚类后的各个分组分别进行PCA运算, 最后利用BP神经网络对所有主成分进行编码压缩。该文的创新点在于BP神经网络压缩图像时, 在训练步骤过程中, 误差反向传播是用原图与输出作差值, 再反向调整各层的权值、阈值。对高光谱图像进行波段聚类, 不仅能够有效地利用谱间相关性, 提高压缩性能, 还可以降低PCA的运算量。实验结果表明, 该文算法与其它现有算法比较, 在相同压缩比下, 其光谱角更小, 信噪比更高。

关键词: 高光谱图像压缩; 波段聚类; 主成分分析; 神经网络

中图分类号: TP751.1

文献标识码: A

文章编号: 1009-5896(2018)10-2478-06

DOI: 10.11999/JEIT180055

Hyperspectral Image Compression Based on Adaptive Band Clustering Principal Component Analysis and Back Propagation Neural Network

CHEN Shanxue ZHANG Yanqi

^①(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

^②(Chongqing Key Laboratory of Mobile Communications Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Hyperspectral remote sensing images have a wealth of spectral information and a huge universe of data. In order to utilize effectively hyperspectral image data and promote the development of hyperspectral remote sensing technology, a hyperspectral image compression algorithm based on adaptive band clustering Principal Component Analysis (PCA) and Back Propagation (BP) neural network is proposed. Affinity Propagation (AP) clustering algorithm for adaptive band clustering is used, and PCA is performed on the each band group respectively after clustering. Finally, all principal components are encoded and compressed by BP neural network. The innovation point lies in BP neural network compressed image during the training step, the error of backpropagation is to compare difference between the original image and the output image, and then adjust the weight and threshold of each layer in the reverse direction. Band clustering of hyperspectral images can not only effectively utilize the spectral correlation and improve the compression performance, but also reduce the computational complexity of PCA. Experimental results investigate that the proposed algorithm achieve a better performance on Signal-to-Noise Ratio (SNR) and spectral angle than other algorithm under the same compression ratio.

Key words: Hyperspectral image compression; Band clustering; Principal Component Analysis (PCA); Neural network

收稿日期: 2018-01-16; 改回日期: 2018-05-24; 网络出版: 2018-07-30

*通信作者: 张燕琪 752910311@qq.com

基金项目: 国家自然科学基金(61271260), 重庆市教委科学技术研究项目(KJ1400416)

Foundation Items: The National Natural Science Foundation of China (61271260), The Science and Technology Research Item of Chongqing Education Commission (KJ1400416)

1 引言

高光谱图像^[1-4]是一个3维的数据，分别是2维的空间信息和1维的光谱信息，波段数目多，数据量大，为快速传输和存储带来了巨大的压力。近年来，遥感技术飞速发展，高光谱图像广泛地应用在对地物的分类和目标识别等方面。为了能有效地节约存储空间，必须对其进行有效的压缩。

高光谱图像压缩方法基本分为3类：基于预测的编码方法，基于变换的编码方法和基于矢量量化的编码方法^[5-10]。对高光谱图像进行压缩一般是几种方法结合起来，单一的方法无法取得良好的效果。基于矢量量化的编码方法，用于无损压缩，计算复杂度高。目前，神经网络^[11]是非常火热的研究方向，许多复杂的应用(比如模式识别、自动控制)和高级模型(比如深度学习)都是基于神经网络，图像的相关研究也广泛地开始涉及神经网络，比如图像分类，目标探测等等。文献^[12]提出一种基于稀疏表示的高光谱图像压缩算法，算法可以很好地保留高光谱数据的光谱信息，但其具有较高的计算复杂度，信噪比也较低。

综上所述，本文提出一种基于自适应波段聚类PCA与BP神经网络结合的高光谱图像压缩算法。算法首先利用近邻传播(Affinity Propagation, AP)聚类在谱间相关性上对高光谱波段进行聚类，然后对聚类后的各个分组分别进行PCA运算，最后利用BP神经网络对各个分组的主成分进行编码压缩。本文算法在BP神经网络训练过程中，误差反向传播对各层的权值、阈值进行调整时是以原图与神经网络压缩解码后的图像作的差值为依据，然后再对高光谱图像进行压缩解压缩。实验结果证明了本文算法的有效性。

2 基本算法介绍

2.1 AP聚类算法介绍

高光谱图像波段聚类传统方法是K均值聚类^[13]。这个方法是迭代求取的最终的聚类划分，即聚类中心与隶属度值。其需要提前给定聚类数目，且不能保证能够找到所求问题的最优解，并很有可能收敛到局部极值。而近邻传播聚类算法是一种半监督聚类算法，是通过将每个数据看成图中的一个节点，迭代过程则是在图中通过传播消息来找到聚类集合。AP聚类算法不需要事先指定类的个数，对初值的选取不敏感，数据点之间传递两种消息，吸引度(responsibility) $r(i, k)$ 和归属性(availability) $a(i, k)$ 。AP聚类算法只有一个唯一输入参数—偏向参数 p 。偏向参数 p 越大，聚类数目越多。本文中偏向

参数的选择与高光谱图像谱间相关性的大小有关，将谱间相关性大小按从小到大排序，取其中间值进行分类，得到的聚类效果较好。

2.2 PCA简介

高光谱图像主成分分析(Principal Component Analysis)^[14]的具体步骤如下：

假设样本观测数据矩阵为

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_1(1,1) & \mathbf{X}_1(1,2) & \cdots & \mathbf{X}_1(M,N) \\ \mathbf{X}_2(1,1) & \mathbf{X}_2(1,2) & \cdots & \mathbf{X}_2(M,N) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{X}_L(1,1) & \mathbf{X}_L(1,2) & \cdots & \mathbf{X}_L(M,N) \end{bmatrix} \quad (1)$$

\mathbf{X} 中的每一行表示一个波段的数据，而 \mathbf{X} 中每一列看作一个 L 维矢量，即

$$\mathbf{X}_i = [x_{1,i}, x_{2,i}, \cdots, x_{L,i}]^T, \quad i = 1, 2, \cdots, MN \quad (2)$$

显然 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \cdots, \mathbf{X}_{MN}]$ ， L 为所取图像数据的波段数目，本文中，实验数据大小为 $256 \times 256 \times 224$ ， L 的取值为 $1 \leq L \leq 224$ 。

步骤1 计算每个分组波段的样本均值。 $\boldsymbol{\mu}$ 为一个分组图像的平均图像向量，其中，

$$\boldsymbol{\mu} = \frac{1}{W} \sum_{i=1}^W Z_i \quad (3)$$

Z_i 为图像均值， W 为分组中波段的个数；

步骤2 计算分组的协方差矩阵。每个分组的协方差矩阵为

$$\boldsymbol{\Sigma} = \frac{1}{W} \sum_{i=1}^W (Z_i - \boldsymbol{\mu})(Z_i - \boldsymbol{\mu})^T \quad (4)$$

步骤3 计算协方差矩阵特征和特征向量。 \mathbf{C}_l 为 $L \times L$ 的对称矩阵。则存在正交矩阵： $\mathbf{U} = [u_1, u_2, \cdots, u_L]$ ，使得 \mathbf{C}_l 可对角化，即

$$\mathbf{U}^T \mathbf{C}_l \mathbf{U} = \boldsymbol{\Lambda} = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_L \end{bmatrix} \quad (5)$$

式中， $\{\lambda_1, \lambda_2, \cdots, \lambda_L\}$ 为 \mathbf{C}_l 的特征值，且 $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_L \geq 0$ ， \mathbf{u}_i 为 \mathbf{C}_l 第 i 个特征值对应的特征向量($i = 1, 2, \cdots, L$)；

步骤4 对每个分组样本矩阵进行降维。每个分组根据设定的阈值，选取大于阈值的特征值所对应的特征向量组成投影矩阵，用样本矩阵乘以投影矩阵即可得到经过PCA降维后的主成分。

2.3 BP神经网络

BP(Back Propagation)神经网络^[15]是一种多层的前馈神经网络，是由输入层，隐含层和输出层3部分组成。其主要的特点是：信号是前向传播

的, 而误差是反向传播的。BP神经网络^[16]用于图像压缩的基本思路是: 网络输入为原始图像数据, 输出代表重建图像, 中间隐含层神经元的输出是需存储的图像特征。不同数目的隐含层节点可实现同一图像的不同压缩比。图1是3层的BP神经网络。

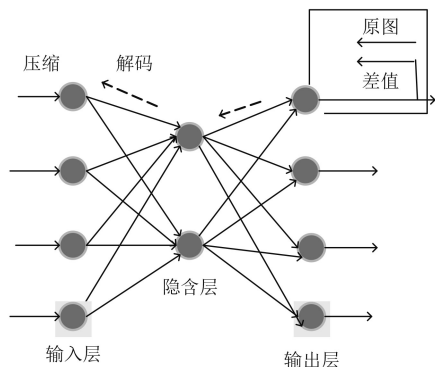


图1 BP神经网络

本文中BP神经网络的输入是指波段聚类后形成的各个分组通过PCA降维得到的数据, 进行误差反向传播时是将原图与其经过BP神经网络后的输出作的差值, 如图1方框所示。如此可避免经过BP神经网络压缩解码以后进行PCA逆变换带来的2次误差。BP神经网络的误差反向传播算法是典型的有导师指导的学习算法。在有导师学习中, 需要为学习规则提供一系列正确的网络输入/输出对, 当网络输入时, 将网络输出与相对应的期望值进行比较, 然后应用学习规则调整权值与阈值, 使网络的输出接近于期望值。本文算法的原图相当于“教师信号”, 在训练网络时已输入。

2.4 总体压缩方案

本文算法的主要思路是首先采用AP聚类算法对波段进行自适应聚类分组, 然后对各分组波段分别进行PCA运算, 最后利用BP神经网络对所有主成分进行编码压缩。整个算法的流程图如图2所示。

3 本文算法

本文算法的具体步骤如下:

步骤1 读取高光谱图像, 将3维数据转换成

2维数据格式, 通过AP聚类算法将高光谱图像波段按照谱间相关性进行分类;

步骤2 根据步骤1得到的分组, 将每一组进行PCA运算。

$$R = \frac{\sum_{i=1}^d \varepsilon}{\sum_{j=1}^n \varepsilon} \quad (6)$$

式中, R 为信息保持率, n 为总特征值个数, d 为实验中选取的特征值个数。在每个分组中, 通过式(6)计算选择信息保持率在99%以上的特征值所对应的特征向量构成投影矩阵 Q 进行下一步运算;

步骤3 各个分组的数据与通过步骤2得到的投影矩阵相乘, 得到降维后的数据。式(7)中, X 为图像原数据, P 为降维后的数据。

$$P = Q'XQ \quad (7)$$

步骤4 将步骤3降维后的数据按占数据集总数的50%和50%分为训练集和测试集(如在实验结果与分析中, Cuprite的3分组有28个波段, 其中14个为训练集, 14个为测试集, 训练集和测试集的大小为 63356×14 , 由于BP神经网络输入神经元不能过大, 所以将其分块输入。由于在AP聚类分组时, Cuprite数据集有分组1, 2, 6, 11为单数, 抽取分组1的最后一个波段放到分组2使它们都为偶数可以按比例分割, 分组6抽取分组7的第1条波段使其成偶数, 但分组7波段数目不变, 分组11与其相同。Jasper Ridge和Lunar Lake数据集如有分组数目为奇数, 其分割方法与Cuprite数据集相同), 并分别把训练集和原图传输到BP神经网络的输入层和输出层。如图1所示, 训练BP神经网络时, 将输出层的结果与原图数据作差值运算, 再反向调整前一层的权值、阈值, 以此向前一层传递, 并对其权值、阈值进行一一调整, 使输出层的结果与原图数据的差值尽量达到设定的误差值, 训练好BP神经网络后, 再将测试集输入BP神经网络进行图像的压缩与解压缩。测试集输入时, 网络模型已建好, 此时不再需要调整权值与阈值, 所以不需要将原图传输到输出层。

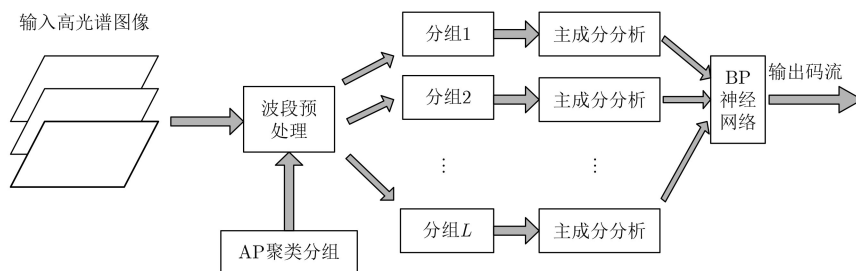


图2 算法整体流程图

4 实验结果与分析

为了验证本文算法的有效性，实验中选取Cuprite, Jasper Ridge和Lunar Lake作为实验数据，图像大小为 $256 \times 256 \times 224$ 。本文运行环境为奔腾双核主频2.7 GHz, 6 GB内存，操作系统Windows 7, Matlab 2014b。并与文献[12]的算法对比来衡量本算法的压缩性能。

AP算法对波段聚类的结果如表1—表3所示。如表所示，根据波段间谱间相关性的大小把波段分组，每个分组的谱间相关性大于不分组时的波段间相关性，有效地去除了谱间冗余，并充分利用了高光谱图像之间的谱间相关性。

利用重构图像的信噪比与光谱角来衡量算法的压缩性能。高光谱图像光谱波段数目多，光谱角是高光谱压缩性能的质量评价之一。光谱角 (Spectral Angle, SA)定义为两个向量的夹角。平均光谱角越小，表明重构图像与原始图像越接近。

$$\text{SNR} = 10 \lg \frac{p_x}{\text{MSE}} \quad (\text{dB}) \quad (8)$$

式中， p_x 表示原始图像信号的能量，MSE表示重构图像与原始图像的误差。

$$\text{SA} = \arccos \left(\frac{\langle s_1, s_2 \rangle}{\sqrt{\langle s_1, s_1 \rangle \langle s_2, s_2 \rangle}} \right) \quad (9)$$

$$\text{ASA} = \frac{1}{MN} \sum_{i,j} \text{SA}_{i,j} \quad (10)$$

其中， s_1, s_2 表示高光谱图像的两条光谱曲线， $\text{SA}_{i,j}$ 表示空间位置为 (i, j) 的重建像元与原始像元之间的光谱角。

本文算法与文献[12]算法，3D-SPIHT (LEVEL3), 3D-SPIHT(LEVEL5)的率失真性能比较如图3所示。LEVEL3和LEVEL5分别表示算法中的3D-SPIHT所使用的小波分别进行3级分解和5级分解。本文算法与文献[12]算法，3D-SPIHT的光谱角性能比较如表4所示。

从图3(a)—图3(c)中可以看出，本文算法与文献[12]算法，3D-SPIHT算法相比较，信噪比有很大提高。这是由于本文算法先对高光谱图像进行

表 1 Cuprite波段聚类分组结果

分组号	1	2	3	4	5	6
各组波段划分	1~17	18~32	33~60	61~74	75~96	97~117
组内相关性	0.9738	0.9998	0.9998	0.9948	0.9997	0.9902
分组号	7	8	9	10	11	12
各组波段划分	118~145	146~161	162~177	178~191	192~202	203~224
组内相关性	0.9961	0.9963	0.9963	0.9925	0.9828	0.8134
不分组时波段间相关性	0.7759					

表 2 Jasper Ridge波段聚类分组结果

分组号	1	2	3	4
各组波段划分	1~24	25~36	37~105	106~113
组内相关性	0.9679	0.9662	0.9663	0.9662
分组号	5	6	7	8
各组波段划分	114~121	122~153	154~166	167~224
组内相关性	0.9665	0.9663	0.9663	0.9664
不分组时波段间相关性	0.6939			

表 3 Lunar Lake波段聚类分组结果

分组号	1	2	3	4	5
各组波段划分	1~19	20~39	40~70	71~107	108~111
组内相关性	0.9704	0.9993	0.9993	0.9972	0.5797
分组号	6	7	8	9	10
各组波段划分	112~155	156~166	167~206	207~221	222~224
组内相关性	0.9742	0.4823	0.9934	0.9868	0.8380
不分组时波段间相关性	0.6413				




图3 率失真性能比较

表4 光谱角对比

比特率(bit/s)	Cuprite			Jasper Ridge			Lunar Lake		
	本文算法	文献[12]算法	3D-SPIHT	本文算法	文献[12]算法	3D-SPIHT	本文算法	文献[12]算法	3D-SPIHT
0.1	0.4842	0.5922	18.4829	1.5030	4.0054	43.8099	0.5151	0.6494	4.7773
0.2	0.3898	0.5179	6.2616	1.4196	3.1861	24.8005	0.4620	0.5847	1.1188
0.4	0.2820	0.4531	1.8106	1.3757	2.8051	8.2692	0.3331	0.5217	0.8408
0.7	0.2697	0.3956	0.7953	1.2893	2.4240	3.3733	0.3325	0.4599	0.4622

AP聚类,充分地利用了谱间相关性。聚类后每个分组分别进行PCA运算,PCA不仅可以用作特征的降维,还可以消除数据中的噪声,并且能与被处理数据的统计特性很好地匹配。

表4给出了本文算法与文献[12]算法以及3D SPIHT算法的对比。如表4所示,本文算法在光谱角性能方面优于对比算法,从侧面验证了本文算法的有效性。

5 结束语

本文通过利用高光谱图像波段之间的相关性,提出了基于自适应波段聚类PCA和BP神经网络的高光谱图像压缩算法。实验结果表明在相同压缩比下,本文算法与对比算法相比较,其信噪比有所提高,光谱角有所下降,验证了本文算法的有效性。本文算法在BP神经网络对图像进行压缩时,误差反向调整权值、阈值过程中,输出的数据和原图作差值运算,省略PCA逆变换步骤,减少了计算量和运算时间。但本文算法存在BP神经网络训练时间长,易陷于局部最小值等不足,通过结合优化算法调整BP神经网络的权值、阈值是未来需要研究的工作之一。

参考文献

- [1] BIOUCA-DIAS J, PLAZA A, CAMPS-VALLS G, *et al.* Hyperspectral remote sensing data analysis and future challenges[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2013, 1(2): 6–36. doi: [10.1109/MGRS.2013.2244672](https://doi.org/10.1109/MGRS.2013.2244672).
- [2] SHEN Hongda, PAN W D, WU Dongsheng, *et al.* Fast Golomb coding parameter estimation using partial data and its application in hyperspectral image compression[C]. Southeastcon, Norfolk, USA, 2016: 1–7. doi: [10.1109/SECON.2016.7506666](https://doi.org/10.1109/SECON.2016.7506666).
- [3] FU Wei, LI Shutao, FANG Leyuan, *et al.* Adaptive spectral-spatial compression of hyperspectral image with sparse representation[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2017, 55(2): 671–682. doi: [10.1109/TGRS.2016.2613848](https://doi.org/10.1109/TGRS.2016.2613848).
- [4] LANDGREBE D. Hyperspectral image data analysis[J]. *IEEE Signal Processing Magazine*, 2002, 19(1): 17–28. doi: [10.1109/79.974718](https://doi.org/10.1109/79.974718).
- [5] 陈善学, 韩勇, 于佳佳, 等. 矢量维数分割量化的高光谱图像压缩方法[J]. *系统工程与电子技术*, 2013, 35(9): 1989–1993. doi: [10.3969/j.issn.1001-506x.2013.09.31](https://doi.org/10.3969/j.issn.1001-506x.2013.09.31).
CHEN Shanxue, HAN Yong, YU Jiajia, *et al.* Compression algorithm of hyperspectral image based on vector dimension segmentation quantization[J]. *Journal of Systems Engineering and Electronics*, 2013, 35(9): 1989–1993. doi: [10.3969/j.issn.1001-506x.2013.09.31](https://doi.org/10.3969/j.issn.1001-506x.2013.09.31).
- [6] KARAMI A, YAZDI M, and MERCIER G. Compression of hyperspectral images using discrete wavelet transform and tucker decomposition[J]. *IEEE Journal on Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, 5(2): 444–450. doi: [10.1109/JSTARS.2012.2189200](https://doi.org/10.1109/JSTARS.2012.2189200).

- [7] MIELIKAINEN J and HUANG B. Lossless compression of hyperspectral images using clustered linear prediction with adaptive prediction length[J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(6): 1118–1121. doi: [10.1109/LGRS.2012.2191531](https://doi.org/10.1109/LGRS.2012.2191531).
- [8] ZHU Shiping and ZONG Xianzi. Fractal lossy hyperspectral image coding algorithm based on prediction[J]. *IEEE Access*, 2017, 5: 21250–21257. doi: [10.1109/ACCESS.2017.2755681](https://doi.org/10.1109/ACCESS.2017.2755681).
- [9] SHEN Hongda, PAN W D, and WU Dongsheng. Predictive lossless compression of regions of interest in hyperspectral images with no-data regions[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2016, 55(1): 173–182. doi: [10.1109/TGRS.2016.2603527](https://doi.org/10.1109/TGRS.2016.2603527).
- [10] WEN Jia, MA Caiwen, and ZHAO Junsuo. FIVQ algorithm for interference hyper-spectral image compression[J]. *Optics Communications*, 2014, 322(8): 97–104. doi: [10.1016/j.optcom.2014.02.016](https://doi.org/10.1016/j.optcom.2014.02.016).
- [11] 韩力群. 神经网络理论、设计及应用[M]. 第2版, 北京: 化学工业出版社, 2007: 第3章.
HAN Liqun. Artificial Neural Network Theory, Design and Application[M]. Second Edition, Beijing: Chemical Press, 2007: Chapter three.
- [12] 吴倩, 张荣, 徐大卫. 基于稀疏表示的高光谱数据压缩算法[J]. 电子与信息学报, 2015, 37(1): 78–84. doi: [10.11999/JEIT140214](https://doi.org/10.11999/JEIT140214).
WU Qian, ZHANG Rong, and XU Dawei. Hyperspectral data compression based on sparse representation[J]. *Journal of Electronica & Information Technology*, 2015, 37(1): 78–84. doi: [10.11999/JEIT140214](https://doi.org/10.11999/JEIT140214).
- [13] 高放, 孙长建, 邵庆龙, 等. 基于K-均值聚类 and 传统递归最小二乘法的高光谱图像无损压缩[J]. 电子与信息学报, 2016, 38(11): 2709–2714. doi: [10.11999/JEIT151439](https://doi.org/10.11999/JEIT151439).
GAO Fang, SUN Changjian, SHAO Qinglong, et al. Lossless compression of hyperspectral image using K-means clustering and conventional recursive least-squares predictor[J]. *Journal of Electronica & Information Technology*, 2016, 38(11): 2709–2714. doi: [10.11999/JEIT151439](https://doi.org/10.11999/JEIT151439).
- [14] FOWLER J E. Compressive-projection principal component analysis[J]. *IEEE Transactions on Image Processing*, 2009, 18(10): 2230–2242. doi: [10.1109/TIP.2009.2025089](https://doi.org/10.1109/TIP.2009.2025089).
- [15] WEI Jia. Application of hybrid back propagation neural network in image compression[C]. International Conference on Intelligent Computation Technology and Automation, Nanchang, China, 2016: 209–212. doi: [10.1109/ICICTA.2015.60](https://doi.org/10.1109/ICICTA.2015.60).
- [16] 闫红梅, 吴冬梅. 改进BP网络在超光谱图像压缩中的应用[J]. 图学学报, 2013, 34(5): 110–114. doi: [10.3969/j.issn.2095-302X.2013.05.022](https://doi.org/10.3969/j.issn.2095-302X.2013.05.022).
YAN Hongmei and WU Dongmei. Application of improved BP neural network in hyperspectral image compression[J]. *Journal of Engineering Graphics*, 2013, 34(5): 110–114. doi: [10.3969/j.issn.2095-302X.2013.05.022](https://doi.org/10.3969/j.issn.2095-302X.2013.05.022).
- 陈善学: 男, 1966年生, 教授, 研究方向为图像处理、数据压缩。
张燕琪: 女, 1992年生, 硕士生, 研究方向为高光谱图像压缩。