

文章编号: 1001-3806(2017)06-0921-06

基于光谱梯度角的高光谱影像流形学习降维法

向英杰, 杨 枕*, 张俭峰, 王 琪

(空军航空大学 航空航天情报系, 长春 130000)

摘要: 为了挖掘高光谱数据的光谱局部特征, 从高光谱遥感数据内在的非线性结构出发, 提出了一种基于光谱梯度角的高光谱影像流形学习降维方法。采用局部化流形学习算法局部保持投影(LPP)对高光谱遥感数据进行非线性降维, 对距离度量进行改进, 将能够更好刻画高光谱影像光谱局部特征的光谱梯度角相似性度量应用于LPP方法, 并用真实高光谱图像进行降维实验, 取得了优于LPP方法和采用光谱角的LPP方法的结果。结果表明, 在光谱规范化特征值方面, 所提方法优于LPP方法和采用光谱角的LPP方法; 在信息量的保持方面, 具有更好的局部细节信息保持量。采用光谱梯度角的流形学习方法用于高光谱影像降维能取得较好的降维效果。

关键词: 光谱学; 流形学习; 降维; 局部保持投影算法; 光谱梯度角

中图分类号: TP751.1

文献标志码: A

doi: 10.7510/jgjs.issn.1001-3806.2017.06.030

Dimensionality reduction for hyperspectral imagery manifold learning based on spectral gradient angles

XIANG Yingjie, YANG Guang, ZHANG Jianfeng, WANG Qi

(Department of Aerospace Intelligence, Aviation University of Air Force, Changchun 130000, China)

Abstract: In order to extract the local characteristics of hyperspectral data, a dimensionality reduction method of hyperspectral imagery manifold learning based on spectral gradient angle was proposed from the nonlinear structure of hyperspectral imagery. Locality preserving projection (LPP) of localized manifold learning algorithm was performed to reduce the dimensionality of hyperspectral remote sensing data. In order to improve the distance metric, similarity measurement of spectral gradient angle, which can better characterize local features of hyperspectral images, was applied to LPP method. The real hyperspectral images were subjected to dimensionality reduction experiments. The results were better than the original LPP method and the LPP method using the spectral angle. The results show that the proposed method is superior to LPP method and LPP method using the spectral angle in the spectral normalized eigenvalues. Meanwhile, the proposed method can also obtain a good performance in information retention and have better local information retention. Therefore, the manifold learning method with spectral gradient angle has a better performance in dimensionality reduction of hyperspectral images.

Key words: spectroscopy; manifold learning; dimensionality reduction; locality preserving projection algorithm; spectral gradient angle

引 言

高光谱遥感可以在可见光到红外电磁波谱范围内, 以较窄的波段间隔对目标区域内的地物连续成像, 从而使获取的数据具有“图像立方体”的形式和结构, 并且具有“图谱合一”的特性和优势^[1-2]。因此, 高光谱图像能够反映不同地物独特的光谱信息, 有助于更加精细的地物分类和目标识别。但是高数据维、维数

灾难等问题的存在, 使得高光谱影像的降维、目标检测等面临很大的挑战。解决这种问题常用的方法是高光谱数据降维, 它主要是利用较低的数据维数来有效表达高维数据信息。

基于数据变换的方法是应用最广泛的高光谱降维方法, 主要分为线性和非线性两大类^[3]。线性的降维方法主要有主成分分析(principal component analysis, PCA)、独立成分分析(independent component analysis, ICA)和线性判别分析(linear discriminant analysis, LDA)等。然而, 由于太阳辐射的非线性变化和大气中电磁波的非线性传播, 使得高光谱数据具有典型的非线性特性。线性降维方法必然引起误差, 需要使用非线性降维。近年来, 大量的非线性高光谱影像降维方法被提出, 如核方法^[4]、基于流形学习的方法^[5-6]以及

基金项目: 吉林省教育厅“十二五”科研项目(2015448); 吉林省科技发展计划资助项目(20140101213JC)

作者简介: 向英杰(1993-), 男, 硕士研究生, 主要研究方向为高光谱图像解译。

* 通讯联系人。E-mail: yg2599@126.com

收稿日期: 2017-01-07; 收到修改稿日期: 2017-03-06

基于混沌理论的方法^[7]。流形学习方法假设高光谱图像是均匀采样于一个高维欧氏空间中的低维流形,通过从高维采样数据中恢复低维流形结构,并求出相应的嵌入映射,用来实现高光谱影像的维数约简。常用的流形学习方法有局部线性嵌入(locally linear embedding, LLE)^[8]、等距特征映射(isometric mapping, ISOMAP)^[9]、拉普拉斯特征映射(Laplacian eigenmap, LE)^[10]和局部保持投影(locality preserving projection, LPP)^[11]等。

无论是哪一种流形学习算法,都需要计算近邻点。在计算距离时,常采用欧氏距离。但在高光谱数据组成的高维观测空间中,欧氏距离对不同物体光谱曲线的形状不敏感,无法取得很好的效果。为了提高降维效果,研究人员用光谱角(spectral angle, SA)、光谱梯度(spectral gradient, SG)以及光谱信息散度(spectral information divergence, SID)来代替欧氏距离,并取得了较好的效果^[12-14]。但是光谱角和光谱信息散度难以反映光谱局部细节特征的变化,用它们来代替流形学习方法中的欧氏距离在一定程度上能改善算法的性能,但是也存在较大误差。基于此,参考文献[15]中结合光谱梯度与光谱角提出了一种新型测度,在检测效果上得到了一定提升。但是通过将二者进行简单的相乘,并不能很好地提取隐藏的局部信息,同时采用的流形学习方法是全局的方法,不利于高光谱数据局部信息的提取。

为了克服上述方法的弱点,提出了用光谱梯度角(spectral gradient angle, SGA)来代替欧氏距离的流形学习方法。光谱梯度角是先求出两光谱向量的梯度向量,然后求取两梯度向量的梯度角。光谱梯度能够反映光谱局部特征变化,特别是光谱曲线斜率的变化^[16]。本文中在计算近邻点距离时,采用能够刻画光谱局部变化的光谱梯度角来代替欧氏距离,然后根据距离度量改进后的LPP方法对高光谱图像进行降维。

1 算法描述

1.1 LPP 算法

HE等人基于LE算法进一步提出了LPP算法^[11]。其基本思想是利用数据集在特征空间中的局部邻域关系导出一个线性变换,使原始数据集中的局部邻域关系在低维子空间中得以保留。

设高维数据点集为 $X = \{x_i\}$,低维数据集为 $Y = \{y_i\}$ (其中, m 为数据点数, $i = 1, 2, 3, \dots, m$),投影矩阵为 A 。因此,利用投影矩阵将高维数据集投影到低维特征空间得:

$$Y = A^T X \quad (1)$$

LPP算法的详细步骤归纳如下。

(1) 构造邻域图 G

邻域图 G 有 m 个节点,找到数据集 x_i 中的 k 个最近邻点。通常有两种方法:第1种是 ε 阈值法;第2种是 k 近邻法。本文中选择 k 近邻法:计算数据点 x_i 和其余全部数据点间的欧氏距离,选距离最近的 k 个数据点为最近邻点。

(2) 设置权重矩阵 W

$W = [w_{ij}]$ 是大小为 $m \times m$ 的稀疏对称矩阵,可以通过简单方法或者热核函数法来设置权重值 w_{ij} 。本文中采用热核方法,当 x_i 和 x_j 是近邻时,有:

$$w_{ij} = \exp(-\|x_i - x_j\|^2 t^{-1}) \quad (2)$$

式中, t 为热核参量。当 x_i 和 x_j 不是近邻时, $w_{ij} = 0$ 。

(3) 计算低维嵌入描述 Y

要保持高光谱遥感图像数据集从原始高维数据空间映射到低维嵌入空间后局部流形特征不变,需要使下面的目标函数最小:

$$\sum_{ij} (y_i - y_j)^2 w_{ij} \quad (3)$$

通过简单的代数公式,并将(1)式代入(3)式,目标函数可以简化为:

$$\frac{1}{2} \sum_{ij} (y_i - y_j)^2 w_{ij} =$$

$$A^T X(D - W)X^T A = A^T X L X^T A \quad (4)$$

式中,拉普拉斯矩阵 $L = D - W$,且 $D = \sum_{j=1}^m w_{ij}$ 为对角矩阵。

约束条件为:

$$A^T X D X^T A = I \quad (5)$$

根据约束条件,利用Lagrange乘子法处理(4)式,可得:

$$X L X^T A = \lambda X D X^T A \quad (6)$$

式中, λ 为广义特征值。

计算(6)式的广义特征值 λ 及特征向量,求出特征值中最小的前 d 个值所对应的特征向量 a_1, a_2, \dots, a_d ,则得投影矩阵 $A = [a_1, a_2, \dots, a_d]$ 。因此,在遇到新样本时,可通过投影矩阵直接得到低维嵌入描述,即有 $Y = A^T X$ 。

1.2 光谱梯度角

光谱梯度角对两光谱向量首先进行1阶求导,获得其梯度向量,然后求取两梯度向量的广义夹角。对于任意两个光谱向量 x 和 y ,光谱梯度表示为:

$$S(x) = [x_2 - x_1, x_3 - x_2, \dots, x_n - x_{n-1}] \quad (7)$$

$$S(y) = [y_2 - y_1, y_3 - y_2, \dots, y_n - y_{n-1}] \quad (8)$$

式中, n 为波段数量。

则光谱梯度角为:

$$\theta_{SGA}(x, y) = \arccos \frac{\langle \mathbf{S}(x), \mathbf{S}(y) \rangle}{|\mathbf{S}(x)| |\mathbf{S}(y)|} \quad (9)$$

1.3 距离度量改进

对于高光谱图像而言,合适的光谱区分方法更能够描述光谱之间的相似性。由(9)式可知,光谱梯度角能够描述光谱的形状及其局部特征。因此在本文方法中,用光谱梯度角代替欧氏距离来构造邻域图 G ,即当 $\theta_{SGA}(x, y) < \hat{\varepsilon}$ 时,光谱 y 为光谱 x 的近邻点,其中, $\hat{\varepsilon}$ 为邻近点距离阈值。

本文中采用热核方法来计算权重矩阵 W 。与欧氏距离相比,测地距离更能反映高维流形的内部结构。因此,在使用热核方法时,选用测地距离来计算。即权重矩阵 $\hat{w}_{ij} = \exp\left[-\frac{d_G(x, y)}{t}\right]$,其中 $d_G(x, y)$ 为光谱 y 和光谱 x 之间的测地距离。

2 实验验证

2.1 数据描述

实验一数据:采用美国 AVIRIS 传感器在 1998 年获取的圣地亚哥机场数据作为实验数据。该图像有 220 个波段,地面分辨率为 3.5m。首先去掉 20 个大气吸收的波段,然后去除 11 个低信噪比的噪声波段,最后用于实验的图像总共有 189 个波段。此时的图像大小为 400pixel × 400pixel,截取大小为 256pixel × 256pixel 的区域进行实验,如图 1 所示。

实验二数据:采用 ROSIS 机载光学传感器获取的帕维亚大学图像。原始图像有 610pixel × 340pixel,具有 1.3m 的空间分辨率和 115 个波段。在本文中,去除 12 个噪声波段,剩余 103 个波段用于实验,如图 2



Fig. 1 The 20th band image of San Diego airport



Fig. 2 The 20th band image of PAVIA university

所示。

2.2 降维结果及分析

本文中采用 LPP 算法来进行实验,并且用 SGA 作为相似性度量来寻找近邻点,即采用 SGA 的 LPP 算法(以下简称 SGA-LPP)。为了比较算法的降维效果,将之与 LPP 算法以及采用 SA 为相似性度量的 LPP 算法(以下简称 SA-LPP)进行对比分析。

实验中,通过残差方法^[17]来确定 k 值, k 值取为 15。图 3 为数据 1 的 4 种方法降维后前 6 个主成分的图像。图 3a 为 LPP 方法前 6 个分量图像;图 3b 为 SA-LPP 方法前 6 个分量图像;图 3c 为 SGA-LPP 方法

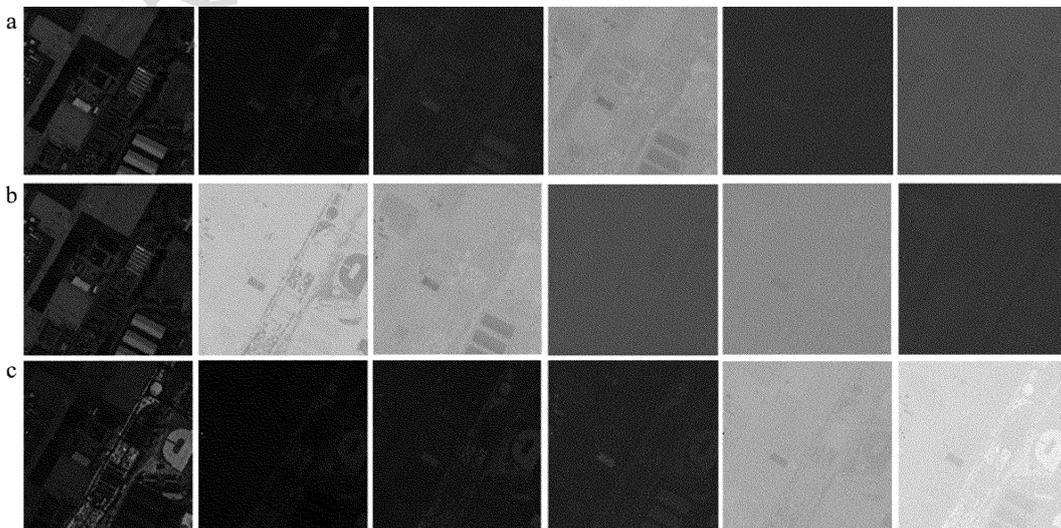


Fig. 3 Dimensionality reduction results of data 1 by three algorithms
a—LPP algorithm b—SA-LPP algorithm c—SGA-LPP algorithm

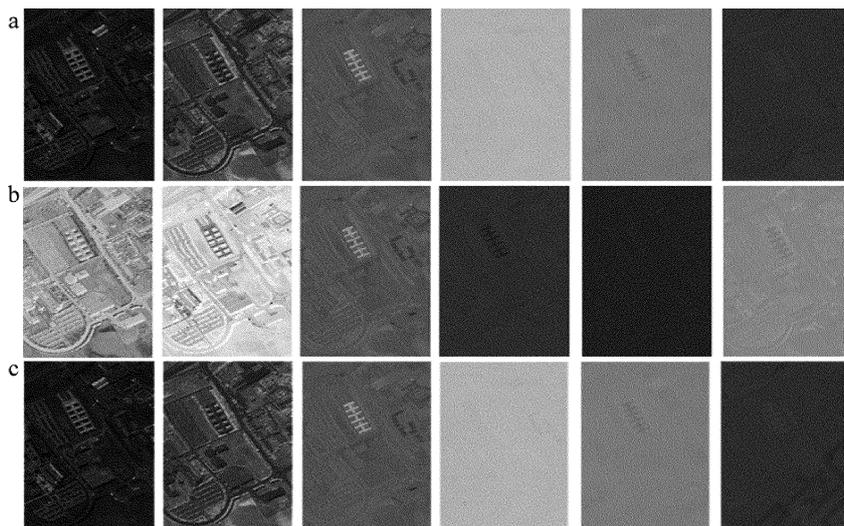


Fig. 4 Dimensionality reduction results of data 2 by three algorithms
a—LPP algorithm b—SA-LPP algorithm c—SGA-LPP algorithm

前 6 个分量图像。图 4 为数据 2 的 4 种方法降维后前 6 个主成分的图像。图 4a 为 LPP 方法前 6 个分量图像;图 4b 为 SA-LPP 方法前 6 个分量图像;图 4c 为 SGA-LPP 方法前 6 个分量图像。从图 3 和图 4 可以看出,SGA-LPP 算法降维结果的前 6 个主成分信息丰富,而且细节表现清楚。与 LPP 方法和 SA-LPP 方法相比,由 SGA-LPP 方法得到的降维结果,各个分量信息量递减较慢,各个分量对局部细节信息的表现能力强。图 5 通过对 LPP,SA-LPP 和 SAG-LPP 3 种方法的规则化特征谱,即特征值/最大特征值进行比较。图 5a 为数据 1 的 3 种方法的规则化谱图;图 5b 为数据 2

的 3 种方法的规则化谱图。可以看出,LPP 方法的规则化特征谱在前 5 个成分下降了两个数量级,SAG-LPP 方法在规则化特征值上优于 LPP 方法和 SA-LPP 方法,说明 SAG-LPP 方法的信息量更集中于前几个分量上。

运用 LPP 算法对高光谱数据进行降维需要选择邻域参量 k 和降维后的维数 d ,参量 k 的选择对降维结果影响很大,本文中通过残差方法来确定 k 值。因为 LPP 方法需要先进行邻域的构建,所以在计算时间上,SAG-LPP 方法需要计算光谱梯度角来构造邻域,因此,LPP 方法和 SA-LPP 方法在计算时间上要优于 SGA-LPP 方法。但是,基于 LPP 方法的流形方法可以更好地揭示高光谱数据的内在结构,能够很好地保持信息量,并且 SAG-LPP 方法具有更好的信息保持量、更好的局部细节信息量。

为了更加客观地分析本文中方法的图像降维效果,现用信息保持率 (retention rate of information, RRI)、均方误差 (mean squared error, MSE) 和边缘强度 (edge intensity, EI) 4 个指标进行对比分析,如表 1、表 2 所示。其中,信息保持率为前 6 个主成分的累积保持率;方差为前 6 个成分均方误差的平均值;边缘强度为降维结果前 6 个主成分的平均边缘强度。可以看出,本文中方法得到的前 6 个主成分在信息保持率上高于 LPP 方法和 SA-LPP 方法;6 个主成分的均方误差平均值与 SA-LPP 方法接近,且低于 LPP 方法,均方误差值越小,说明本文中降维结果越好;本文中方法所得结果的边缘强度最高,说明图像边缘保持效果越好,能够更好地应用于后续的地物分类和目标检测。

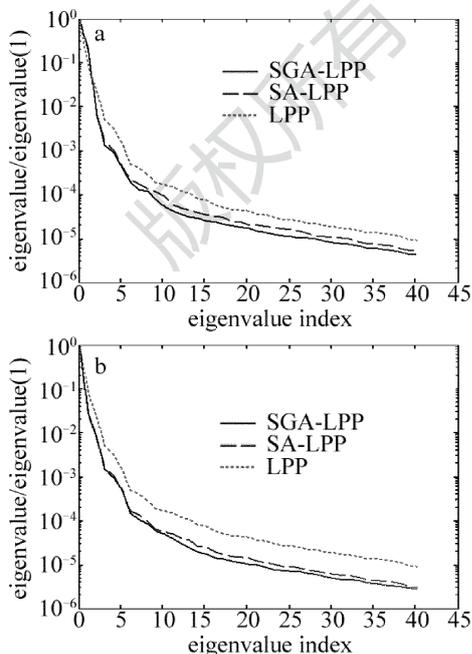


Fig. 5 Comparison of the normalized eigenspectra by LPP, SA-LPP and SGA-LPP
a—data 1 b—data 2

图 6a 和图 7a 中分别为 LPP 方法 1-2-3 分量 (即第 1、第 2、第 3 主成分,下同) 和 4-5-6 分量 (即第 4、第

Table 1 Index evaluation of dimension reduction for data 1

algorithms	RRI	MSE	EI
LPP	89.35%	1.7637×10^6	4.54
SA-LPP	92.41%	1.4554×10^6	6.33
SGA-LPP	94.54%	1.5469×10^6	6.98

Table 2 Index evaluation of dimension reduction for data 2

algorithms	RRI	MSE	EI
LPP	88.42%	2.4735×10^6	5.24
SA-LPP	90.87%	1.8373×10^6	7.85
SGA-LPP	93.19%	1.9724×10^6	8.20

5、第 6 主成分,下同)合成的 RGB 图像;图 6b 和图 7b 中分别为 SA-LPP 算法 1-2-3 分量和 4-5-6 分量合成的 RGB 图像;图 6c 和图 7c 中分别为 SGA-LPP 算法 1-2-3 分量和 4-5-6 分量合成的 RGB 图像。由图 6 和图 7 比较可知,SGA-LPP 方法降维得到的分量合成后的图像最清楚、平滑,局部细节最丰富。与 LPP 方法和 SA-LPP 方法相比,SGA-LPP 方法的 1-2-3 分量和 4-5-6 分量合成的 RGB 图像均具有较好的局部细节表现能力,且 4-5-6 分量合成图像也具有一定的信息量。由于高光谱数据存在固有的非线性特性,流形学习能更好地揭示高光谱数据的本征结构和非线性特性。流形学习方法进行高光谱数据的降维,具有更好地准确度。同时,更加合理的光谱相似性度量能够更好地描述高光

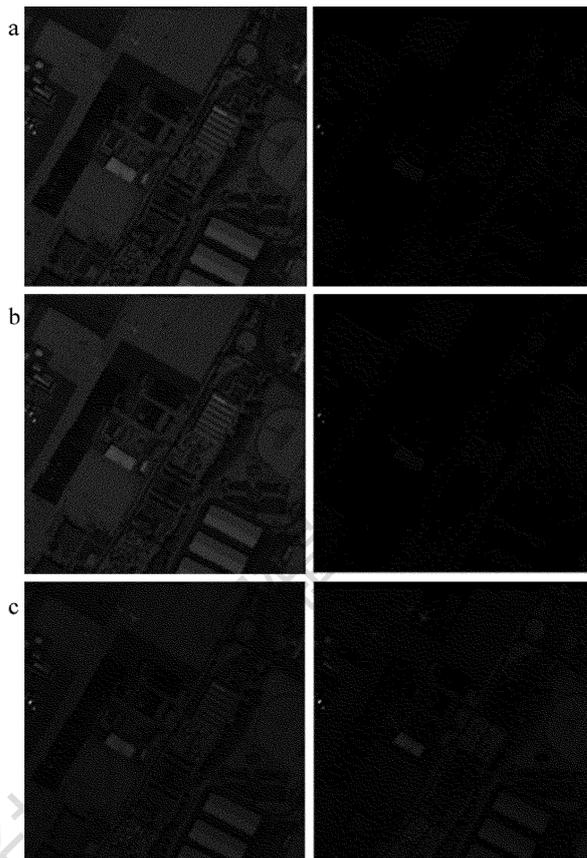


Fig. 6 RGB fusion results of data 1

谱数据,将之应用于流形学习方法能够取得更好的降



Fig. 7 RGB fusion results of data 2

维效果。

3 结 论

针对高光谱遥感数据的特点,将流形学习方法应用于高光谱数据,利用 LPP 算法对高光谱图像进行降维。考虑光谱的局部特征变化,将光谱梯度角应用于改进距离计算,提出了 SGA-LPP 方法,同时将 LPP 方法和 SA-LPP 方法降维结果进行比较。在光谱规范化特征值方面,SGA-LPP 方法优于 LPP 方法和 SA-LPP 方法;在信息量的保持方面,SGA-LPP 方法也取得了很好的结果,各个分量间的信息量递减较慢,从而可以很好地保持局部细节信息,并且揭示了非线性数据的整体结构。由于计算的复杂度,流形学习降维方法在计算时间上不占优势。因此,对大数据量、大尺度的高

光谱数据进行降维,SGA-LPP 方法稍显吃力。如何提高计算效率,实现对大数据量、大尺度的高光谱数据 SGA-LPP 方法降维,是下一步研究的方向。

参 考 文 献

[1] ZHANG B. The advances of hyperspectral image processing and information extraction[J]. Journal of Remote Sensing, 2016, 20(5): 1061-1090(in Chinese).
 [2] JOSÉ M, ANTONIO P, GUSTAVO C, et al. Hyperspectral remote sensing data analysis and future challenges[J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(2):6-36.
 [3] CHEN H D, PU H H, WANG B, et al. Image euclidean distance-based manifold dimensionality reduction algorithm for hyperspectral imagery[J]. Journal of Infrared and Millimeter Waves, 2013, 32(5):450-451(in Chinese).
 [4] MULLER K R, MIKA S. An introduction in kernel-based learning algorithms[J]. IEEE Transactions on Neural Networks, 2001, 12(2): 181-201.

- [5] BACHMANN C M, AINSWORTH T L, FUSINA R A. Exploiting manifold geometry in hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3):441-454.
- [6] BACHMANN C M, AINSWORTH T L, FUSINA R A. Improved manifold coordinate representations of large scale hyperspectral scenes [J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(10):2786-2803.
- [7] ZHANG A, XIE Y. Chaos theory-based data-mining technique for image endmember extraction: Laypunov index and correlation dimension (L and D) [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(4):1935-1947.
- [8] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500):2323-2326.
- [9] TENENBAUM J, SILVA D D, LANGFORD J. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(5500):2319-2323.
- [10] MIKHAIL B, PARTH N. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6):1373-1396.
- [11] HE X F, NIYOI P. Locality preserving projections[J]. Neural Information Processing System, 2004, 16:153-160.
- [12] DU P J, WANG X M, TAN K, *et al.* Dimension reduction and feature extraction of hyperspectral remote sensing imagery using manifold learning[J]. Geomatics and Information Science of Wuhan University, 2011, 36(2):148-152(in Chinese).
- [13] DING L, TANG P, LI H Y. Dimensionality reduction and classification for hyperspectral remote sensing data using ISOMAP[J]. Infrared and Laser Engineering, 2013, 42(10):2707-2711.
- [14] WANG Y T, HUANG S Q, WANG H X, *et al.* Dimensionality reduction for hyperspectral image based on manifold learning[C]//International Conference on Image and Graphics. New York, USA: Springer International Publishing, 2015:164-172.
- [15] WANG L L, LI Z Y, SUN J X, *et al.* New measure based manifold algorithm and application in anomaly detection of hyperspectral imagery[J]. Applied Mechanics and Materials, 2011, 80/81(3):797-803.
- [16] ZHANG X B, YUAN Y, WANG Q. Spectral discrimination method based on information divergence of gradient[J]. Acta Optica Sinica, 2011, 31(5):0530001(in Chinese).
- [17] ZHANG Zh Y, ZHA H Y. Principal manifolds and nonlinear dimensionality reduction via tangent space alignment[J]. SIAM Journal of Scientific Computing, 2004, 26(1):313-338.