

# 基于自动子空间划分的高光谱本征图像分解

任智伟\*, 吴玲达

航天工程大学航天信息学院, 北京 101416

**摘要** 受传感器状态、成像机理、气候、光照等条件的影响, 高光谱遥感图像存在严重的畸变和失真。本征图像分解是计算机视觉及图形学领域广泛应用的图像处理技术, 采用该技术能够获得图像的本质特征。本研究将本征图像分解引入到高光谱图像处理中对原始图像进行本征图像分解。提出了一种基于自动子空间划分的高光谱本征图像分解方法。首先对高光谱图像进行子空间划分, 再对每个子空间应用基于最优化的本征图像分解方法进行分解, 然后对分解得到的反射率本征图像进行高光谱图像分类处理。实验结果表明: 基于自动子空间划分的高光谱本征图像分解能够在较大程度上提高高光谱图像的分类精度。

**关键词** 光谱学; 高光谱图像; 自动子空间划分; 本征图像分解; 最优化

中图分类号 O433.4

文献标识码 A

doi: 10.3788/LOP55.103004

## Hyperspectral Intrinsic Image Decomposition Based on Automatic Subspace Partitioning

Ren Zhiwei\*, Wu Lingda

School of Space Information, Space Engineering University, Beijing 101416, China

**Abstract** Because of the influence of certain operational parameters, such as sensor status, imaging mechanism, climate, and illumination, hyperspectral remote sensing images suffers from serious distortion. Intrinsic image decomposition (IID) is an extensively used image processing technology in the field of computer vision and graphics because it can acquire the essential features of the images that are being processed. IID is introduced to hyperspectral image processing to decompose the original images. Accordingly, we propose a hyperspectral IID method based on automatic subspace partitioning. Firstly, the hyperspectral image is divided into subspaces, and the optimal decomposition-based IID method is applied to each subspace. The reflectance intrinsic image that is obtained from the decomposition is further subjected to hyperspectral image classification processing. The experimental results obtained from this study indicate that the proposed method can considerably improve the accuracy of hyperspectral image classification.

**Key words** spectroscopy; hyperspectral image; automatic subspace partitioning; intrinsic image decomposition; optimization

**OCIS codes** 300.6320; 100.4145; 300.6170

## 1 引言

高光谱图像不仅能够描述地物的空间形态与分布, 还具有光谱分辨率高、光谱连续以及图谱合一等特点, 这使得高光谱遥感在环境监测、气象预测<sup>[1]</sup>、地质勘探<sup>[2]</sup>、林业检测、海洋监测<sup>[3]</sup>以及国防<sup>[4-5]</sup>等方面得到了广泛应用。而高光谱图像分类是诸多应用的第一步, 也是重要的一步。

由于受传感器状态、成像机理、气候、光照等条件的影响, 高光谱遥感图像存在严重的畸变和失真。同时, 图像中不同的地物可能会因密度、所含水分比重等原因而具有相似的光谱特征, 而相同的地物也会因光照、季节等因素产生差异较明显的光谱特征, 即会出现“同谱异物”和“同物异谱”现象。这会对高光谱图像分类产生极大的干扰。

本征图像分解(IID)是在计算机视觉与计算机

收稿日期: 2018-03-14; 修回日期: 2018-05-04; 录用日期: 2018-05-10

基金项目: 国家自然科学基金(61801513)

\* E-mail: juimer@foxmail.com

图形学领域广泛应用的图像处理技术。为了获得图像的本质特征,通常通过原图来求解未知的亮度及反射率本征图,进而对图像进行更准确的描述。一般情况下,对高光谱图像进行处理的依据是不同地物间反射率的差异。因此,通过高光谱本征图像分解得到纯净的反射率本征图,然后再进行处理,将会得到更好的处理结果。

本文在基于最优化的本征图像分解的基础上,提出了一种基于自动子空间划分的高光谱本征图像分解方法。根据波段间的相关性,利用自动子空间划分方法,根据波段间相关性进行子空间划分。对得到的每个子空间,利用基于最优化的本征图像分解方法对每个波段子集进行本征图像分解,然后将分解的反射率本征图进行合并。在实验部分将最终得到的反射率本征图进行高光谱图像分类处理。

## 2 基于最优化的本征图像分解方法

本征图像分解最早由 Barrow 等在 1978 年提出<sup>[6-7]</sup>。本征图像求解问题就是从图像出发,恢复所有像素点对应场景中的亮度和反射率信息,分别形成亮度本征图和反射率本征图。常用的模型为

$$\mathbf{I} = \mathbf{S}\mathbf{R}, \quad (1)$$

式中: $\mathbf{I}$  为输入的原始图像; $\mathbf{S}$  为分解得到的亮度本征图像; $\mathbf{R}$  为分解得到的反射率本征图像。

对于一张输入计算机的图像而言,已知信息只有每个像素点的像素值。这些像素值是由亮度、物体反射率、物体形状、观察视角等因素和属性共同耦合而成的。在这些属性中,最重要的因素就是亮度和反射率。亮度对应环境的光照信息,反射率则对应物体的材质信息<sup>[8]</sup>。在大量的计算机视觉研究与应用中,若能将图像的亮度部分和反射率部分分开,然后进行相应的视觉计算,就会获得更好的结果。透过表面现象,本征特性给出了一个不随亮度变化的、表面更具有区分性的图像,这极大地简化了很多基本的物体识别操作<sup>[9]</sup>。

Land 等<sup>[10]</sup>最早对视网膜成像原理进行了研究,归纳出 Retinex 假设:自然场景中物体纹理的边缘趋向于较为剧烈的变化,而明暗关系的变化则趋近于平滑。此假设也衍生出了一系列算法<sup>[11-12]</sup>。但上述算法均只考虑了相邻像素间的约束关系,属于局部约束,对同种物质相距较远的情况表现较差。近年来,研究人员将全局约束考虑进来<sup>[13-15]</sup>,但此类方法对图像的色度信息过于依赖,在图像中存在深度信息的情况,处理的结果不理想。因此,在处理深

度不连续的现实场景时,研究人员提出了交互式本征图分解方法<sup>[16]</sup>。

基于最优化的本征图像分解方法是 Shen 等<sup>[17]</sup>在 2013 年提出的,其基于的假设是:图像像素的反射分量可以用该像素点邻域内像素点的反射分量的加权和表示。具体表达式为

$$\mathbf{R}_i = \sum_{j \in \mathbf{N}(i)} \omega_{ij} \mathbf{R}_j, \quad (2)$$

$$\omega_{ij} = \exp \left\{ - \left[ \frac{(Y_i - Y_j)^2}{\sigma_{iY}^2} + \frac{A(\mathbf{I}_i, \mathbf{I}_j)^2}{\sigma_{iA}^2} \right] \right\}, \quad (3)$$

式中: $\mathbf{R}_i$  为像素  $i$  的反射率; $\mathbf{N}(i)$  为像素  $i$  的邻域窗口; $\omega_{ij}$  为像素  $i$  与像素  $j$  的相似度,由亮度值相似度与光谱角相似度两部分组成; $Y_i$  为像素  $i$  的亮度值,具体为 R、G、B 值的平均值; $Y_j$  为像素  $j$  的亮度值; $\sigma_{iY}^2$  为像素  $i$  邻域窗口内亮度的方差; $A(\mathbf{I}_i, \mathbf{I}_j)^2$  为像素  $i$  与像素  $j$  之间的光谱角; $\sigma_{iA}^2$  为像素  $i$  邻域窗口内光谱角的方差; $\mathbf{I}_i, \mathbf{I}_j$  为像素  $i$  与像素  $j$  的像素值。

在此基础上,图像的反射率本征图和光照本征图可以采用能量最优化的方式进行求解。能量方程为

$$\mathbf{E}(\mathbf{R}, \mathbf{s}) = \sum_{i \in \mathbf{P}} \left( \mathbf{R}_i - \sum_{j \in \mathbf{N}(i)} \omega_{ij} \mathbf{R}_j \right)^2 + \sum_{i \in \mathbf{P}} (I_i \mathbf{s}_i - \mathbf{R}_i)^2, \quad (4)$$

式中: $\mathbf{P}$  为输入的整幅图像; $\mathbf{s}_i$  为光照本征图  $\mathbf{s}$  的倒数。此能量方程可利用梯度下降法进行求解。

## 3 基于自动子空间划分的高光谱本征图像分解方法

与灰度或彩色本征图像分解相比,高光谱本征图像的分解无疑更加复杂,且充满挑战性。彩色图像的本征分解只关注 3 个通道,即 R、G、B 通道。而高光谱图像具有几十甚至上百个光谱通道,因此,采用传统算法处理高光谱数据往往得不到理想的结果。

Zheng 等<sup>[18]</sup>将光谱本征图像分解视为矩阵低秩分解问题,基于场景的光谱反射分量可被低秩化表征理论,提出了一种尺度化的优化算法。国内学者陈希<sup>[19]</sup>利用此理论进行了高光谱本征图像的分解,并建立了光谱图像数据库。除了低秩化表征理论外,高光谱本征图像的分解通常是将彩色本征图像分解算法进行拓展。戴琼海等<sup>[20]</sup>利用 Retinex 约束、非局部约束等方法对高光谱图像进行分解,利用共轭梯度及字典学习算法得到了本征图。

高光谱图像相较于彩色图像的最大特点是光谱通道数量的增加。基于最优化的本征图像分解方法在彩色图像(包含 R、G、B 3 个光谱通道)中取得了良好的效果<sup>[18]</sup>,因此,将最优化的本征图像分解方法移植到高光谱图像的处理中,在理论上是可行的。但直接对高光谱图像进行分解存在两个主要问题: 1) 计算成本大。高光谱图像的数据量大,若直接对其进行分解,需要的计算成本过于巨大。2) 波段跨度大。原始的高光谱数据波段跨度大,相距较远的波段之间的反射率及对亮度变化的敏感程度相差较大。如果对全部数据进行本征图像分解,则分解结果误差会较大。图 1 为图像处理标准测试图像 Lena 绿、蓝两波段像素值的部分变化曲线。图 2 为高光谱图像处理通用数据集 Indiana Pines 数据集第 20、第 50 波段像素值的部分变化曲线。由图 2 和图 3 可见,彩色图像各波段之间的像素值变化相近,而高光谱图像数据不同波段之间像素值变化的差异较大。

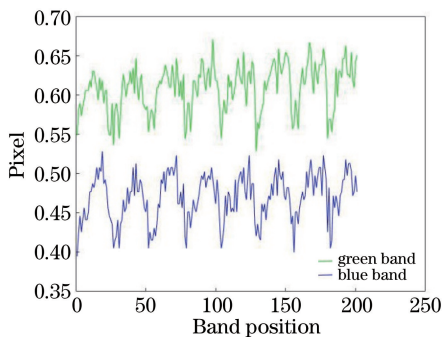


图 1 Lena 图像绿、蓝波段的部分像素值  
Fig. 1 Partial pixel value of green and blue bands of the Lena image

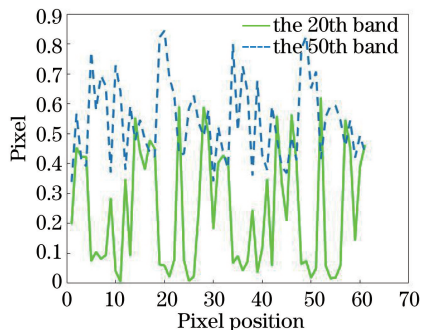


图 2 Indiana Pines 数据集第 20、第 50 波段的部分像素值  
Fig. 2 Partial pixel value for the 20th and 50th bands of the Indiana Pines dataset

因此,本课题组提出了基于自动子空间划分的高光谱本征图像分解方法。一方面,自动子空间划分会降低后续本征图像分解的计算复杂度。在每个

子空间内分别进行本征图像分解,将会极大地降低计算成本。另一方面,子空间内波段之间的相关性高,故而光谱反射率相近,对亮度变化的敏感程度相近。此外,自动子空间划分将极大地降低分解的错误率。

自动子空间划分方法是谷延锋等<sup>[21]</sup>提出的一种数据空间划分方法,该方法利用波段之间的相关性对高光谱数据进行子空间划分。与传统的依照波长区间(如紫外、可见光、红外)的划分方式相比,自动子空间划分方法能够更有效地利用数据的特征。苏红军等<sup>[22]</sup>利用此方法进行了波段选择方法的研究,取得了较好的效果。

自动子空间划分流程如下:

步骤 1): 每个波段像素值构成一个矢量;

步骤 2): 计算相邻波段矢量的相关系数,构成一维相关系数矩阵  $\mathbf{P}$ ;

步骤 3): 提取相关系数矩阵  $\mathbf{P}$  的极小值,并根据极小值对高光谱数据空间进行划分。

图 3 为 Indiana Pines 数据集相邻波段的相关系数变化,从图中可以看出原高光谱数据确实具有分块效应。




图 3 Indiana Pines 数据集相邻波段相关系数的变化(步长为 2)  
Fig. 3 Correlation coefficient of the adjacent bands in the Indiana Pines dataset (steps length is 2)

基于自动子空间划分的高光谱本征图像分解算法流程如下:

步骤 1): 对高光谱数据进行自动子空间划分;

步骤 2): 对每个子空间运用基于最优化的本征图像分解方法进行分解;

步骤 3): 将每个子空间分解得到的反射率本征图按顺序组成原始图像数据的反射率本征图。

## 4 实验结果与分析

在 Intel® Core™ i7-6500U 的 CPU 和 8192 MB 的 RAM 硬件平台上,基于 MATLAB 软件进行实



验。在美国印第安纳州西北部某农林混合实验场采用机载成像光谱仪采集实验数据,得到 Indiana Pines 数据集。图像空间分辨率为 25 m,图像大小为 145 pixel×145 pixel。原始数据具有 224 个光谱波段,波长范围为 0.4~2.5  $\mu\text{m}$ 。最终保留信噪比较

高、质量较好的 200 个波段。最终实验所使用的图像大小为 145 pixel×145 pixel×200,包含 16 个地物类别。

Indiana Pines 数据集灰度图像及地物真实标记如图 4 所示。




图 4 Indiana Pines 数据集灰度图及地物真实标记。(a)灰度图像;(b)地物真实标记

Fig. 4 Grayscale image and real mark of surface features of the Indiana Pines dataset.

(a) Grayscale image; (b) real mark of surface features

图 5(a)、(b)分别为 Indiana Pines 数据集经高光谱本征图像分解后得到的反射分量的灰度图和亮度分量的灰度图。与原始图像相比,反射率本征图更加纯净,且边缘较为清晰,而光照本征图十分斑

驳。值得注意的是,从光照本征图中仍可以看出地物边缘,这说明基于最优化的本征图像分解方法无法将反射率分量与亮度分量完全分开,算法还有待进一步优化。




图 5 Indiana Pines 数据集反射分量和亮度分量的灰度图。(a)反射分量;(b)亮度分量

Fig. 5 Grayscale images of reflection and luminance components of the Indiana Pines dataset.

(a) Reflection component; (b) luminance component

分别对分解得到的反射率本征图和原始高光谱图像进行分类。选用最小距离分类器(MDC)和支持向量机(SVM)分类器。IID-ASP-MDC、ID-ASP-SVM 分别表示将原始高光谱图像进行基于自动子空间划分的高光谱本征图像分解,然后将得到的反射率本征图输入 MDC、SVM 分类器的分类方法。在分类实验中,选取地物像素点总数的 5% 作为训练样本。下面对实验结果进行比较分析。

表 1 给出了 Indiana Pines 数据集各地物的像素点个数、训练样本数及测试样本数。为了客观地表述各方法分类精度的优劣,采用总体分类精度(OA)、平均分类精度(AA)、Kappa 系数以及每种

地物的分类精度作为评价指标。

表 2 为各方法分类精度评价指标的对比,可以看出:使用经过本征图像分解得到的反射率本征图进行分类,得到的分类精度的各项评价指标均比使用原始图像进行分类得到的分类精度高;在 IID-ASP-SVM 得到的分类结果中,“割草后的牧场(grass-pasture-mowed)”与“干草堆(hay-windrowed)”两类地物的分类全部正确;在“玉米地(corn)”、“燕麦(oats)”等地物分类中,普通方法分类的精度较低,而基于本征图像分解的分类方法表现良好。对各方法的 OA、AA、Kappa 系数进行对比后可知,基于本征图像分解的分类方法的 3 种评

价指标均远高于基于原始图像的分类方法。与未经过子空间划分的方法相比,经过自动子空间划分的分类结果更优。对两种本征图像分解方法的计算时间进行多次统计后求平均值,结果显示:未经过自动子空间划分的高光谱本征图像分解方法的计算时间平均为 607.10 s,而所提方法的计算时间为

460.71 s。由此可见,所提方法能够有效降低计算时间。此外,由分类结果可以看出,SVM 分类器的分类精度高于 MDC 的分类精度,SVM 分类器更适合用于高光谱图像的分类。

训练样本数为 0.5% 时,各方法分类精度评价指标的对比结果如表 3 所示,可以看出:当训练样本个

表 1 Indiana Pines 数据集中各类地物的像素点个数、训练样本数及测试样本数

Table 1 Number of pixels, training sample, and test sample of various features in the Indiana Pines dataset

Class number	Feature category	Total number	Number in training	Number in test
1	Alfalfa	47	24	23
2	Corn-notill	1429	41	1388
3	Corn-mintill	831	37	794
4	Corn	238	32	206
5	Grass-pasture	484	35	449
6	Grass-trees	731	35	696
7	Grass-pasture-mowed	28	14	14
8	Hay-windrowed	478	35	443
9	Oats	20	10	10
10	Soybean-notill	972	39	933
11	Soybean-mintill	2455	42	2413
12	Soybean-clean	593	32	561
13	Wheat	205	32	173
14	Woods	1265	36	1229
15	Buildings-grass-trees-drives	386	35	351
16	Stone-Steel-Towers	93	33	60
Total		10249	512	9737

表 2 各方法分类精度的评价指标

Table 2 Evaluation indices of the classification accuracy of each method

Class number	Feature category	MDC	IID-ASP-MDC	SVM	IID-SVM	IID-ASP-SVM
1	Alfalfa	0	0.8519	0.7241	0.3651	0.8846
2	Corn-notill	0.5204	0.8393	0.6784	0.8183	0.9254
3	Corn-mintill	0.6889	0.9647	0.5800	0.7481	0.9880
4	Corn	0.4730	0.6755	0.4058	0.7692	0.8280
5	Grass-pasture	0.8512	0.9512	0.8506	0.8845	0.9977
6	Grass-trees	0.7225	0.9335	0.9312	0.9611	0.9888
7	Grass-pasture-mowed	0.6087	0.4118	0.8125	0.8750	1.0000
8	Hay-windrowed	0.8590	0.9978	0.9887	1.0000	1.0000
9	Oats	0	0.4545	0.3704	0.9091	0.8333
10	Soybean-notill	0.5549	0.7473	0.6973	0.7474	0.8910
11	Soybean-mintill	0.7177	0.9071	0.8388	0.9168	0.9769
12	Soybean-clean	0.4318	0.7305	0.6242	0.8477	0.8787
13	Wheat	0.7463	0.9942	0.9651	0.9889	0.9944
14	Woods	0.8717	0.9955	0.9444	0.9857	0.9952
15	Buildings-grass-trees-drives	0.3404	0.7627	0.5909	0.7610	0.9888
16	Stone-steel-towers	0.9270	0.9811	0.9492	0.8696	0.9714
	OA	0.6757	0.8734	0.7596	0.8640	0.9567
	AA	0.5517	0.8249	0.7470	0.8412	0.9464
	Kappa	0.6277	0.8558	0.7282	0.8455	0.9506

数设置为 0.5% 时,各种方法的精度均大幅下降,但 IID-ASP-SVM 仍表现较好,各类地物分类精度仍明显高于其他方法,甚至高于训练样本为 5% 时的

表 3 训练样本数为 0.5% 时各方法分类精度的评价指标

Table 3 Evaluation indices of the classification accuracy of each method when the training sample is 0.5%

Index	MDC	IID-ASP-MDC	SVM	IID-SVM	IID-ASP-SVM
OA	0.4901	0.4762	0.4679	0.5405	0.7726
AA	0.2724	0.4461	0.4261	0.6001	0.7364
Kappa	0.3998	0.4078	0.3943	0.4890	0.7407

## 5 结 论

本课题组提出一种基于自动子空间划分的高光谱本征图像分解方法。首先利用自动子空间划分方法对原始高光谱数据进行子空间划分,进而对每个子空间进行基于最优化的本征图像分解。实验部分对高光谱本征图像分解得到的反射率本征图进行图像分类处理。将利用原始图像和未经自动子空间划分得到的反射率本征图进行实验得到的结果进行对比,结果显示:基于高光谱本征图像分解的高光谱图像分类能够得到更高的精度。在训练样本过小的条件下,所提方法仍能取得较好的实验结果。但所提方法仍存在一定不足:没有将高光谱图像的反射率分量与亮度分量完全分开,且计算成本偏高。

除了在图像分类方面的应用,高光谱本征图像分解在其他方面也有着广阔的应用前景,比如目标检测、多源图像融合等。所提方法将本征图像分解方法引入到高光谱图像处理领域,对遥感图像处理具有一定的借鉴作用。在今后的研究中,将重点研究效率更高的高光谱本征图像分解方法,以及它在其他处理中的应用。

## 参 考 文 献

- [1] Ma P F, Chen L F, Li Q, *et al.* Simulation of atmospheric nitrous oxide profiles retrieval from AIRS observations [J]. *Spectroscopy and Spectral Analysis*, 2015, 35(6): 1690-1694.  
马鹏飞, 陈良富, 厉青, 等. 红外高光谱资料 AIRS 反演晴空条件下大气氧化亚氮廓线[J]. *光谱学与光谱分析*, 2015, 35(6): 1690-1694.
- [2] Rinker J N. Hyperspectral imagery: a new technique for targeting and intelligence [R]. Washington: Directorate for Information Operations and Reports, 1990: 2-7.
- [3] Muller-Karger F, Roffer M, Walker N, *et al.* Satellite remote sensing in support of an integrated

MDC 分类。从结果中可以看出:基于本征图像分解的高光谱图像 SVM 分类方法在训练样本数过小的情况下同样适用。

ocean observing system [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2013, 1(4): 8-18.

- [4] Zhang C Y, Cheng H F, Chen Z H, *et al.* The development of hyperspectral remote sensing and its threatening to military equipments[J]. *Electro-Optic Technology Application*, 2008, 23(1): 10-12  
张朝阳, 程海峰, 陈朝辉, 等. 高光谱遥感的发展及其对军事装备的威胁[J]. *光电技术应用*, 2008, 23(1): 10-12.
- [5] Liu K L, Sun X J, Zhao Z Y, *et al.* Spectrum imaging test method for camouflage characteristic of ground target [J]. *Journal of PLA University of Science and Technology (Natural Science Edition)*, 2005, 6(2): 166-169.  
刘凯龙, 孙向军, 赵志勇, 等. 地面目标伪装特征的高光谱成像检测方法[J]. *解放军理工大学学报(自然科学版)*, 2005, 6(2): 166-169.
- [6] Barrow H G, Tenenbaum J M. Recovering intrinsic scene characteristics from images [M]. New York: Academic Press, 1978: 3-26.
- [7] Guo Y B. Research and application of intrinsic image decomposition algorithm [D]. Xiamen: Xiamen University, 2014: 14-16.  
郭银斌. 本征图像分解算法研究及其应用[D]. 厦门: 厦门大学, 2014: 14-16
- [8] Dai H P. Decomposition method and application of intrinsic image [D]. Tianjin: Tianjin University, 2014: 12-13.  
戴海鹏. 本征图像分解方法与应用研究[D]. 天津: 天津大学, 2014: 12-13.
- [9] Yang B J. Geometric feature extraction and shape restoration algorithm based on RGB-D image [D]. Zhengzhou: Zhengzhou University, 2015: 9-11.  
杨秉杰. 基于 RGB-D 图像的几何特征提取及形状恢复算法研究[D]. 郑州: 郑州大学, 2015: 9-11.
- [10] Land E H, McCann J J. Lightness and retinex theory [J]. *Journal of the Optical Society of America*, 1971, 61(1): 1-11.
- [11] Funt B V, Drew M S, Brockington M. Recovering

- shading from color images [J]. Lecture Notes in Computer Science, 1992, 588(12): 124-132.
- [12] Tappen M F, Freeman W T, Adelson E H. Recovering intrinsic images from a single image[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(9): 1459-1472.
- [13] Garces E, Munoz A, Lopez-Moreno J, *et al.* Intrinsic images by clustering[J]. Computer Graphics Forum, 2012, 31(4): 1415-1424.
- [14] Bell S, Bala K, Snavely N. Intrinsic images in the wild[J]. ACM Transactions on Graphics, 2014, 33(4): 1-12.
- [15] Bi S, Han X G, Yu Y Z. An  $L_1$  image transform for edge-preserving smoothing and scene-level intrinsic decomposition[J]. ACM Transactions on Graphics, 2015, 34(4): 1-12.
- [16] Yang X C. Research on solving method of intrinsic image based on learning and interaction[D]. Beijing: Beijing Institute of Technology, 2011: 7-10.  
杨小灿. 基于学习与交互的本征图像求解方法研究[D]. 北京: 北京理工大学, 2011: 7-10.
- [17] Shen J B, Yang X S, Li X L, *et al.* Intrinsic image decomposition using optimization and user scribbles [J]. IEEE Transactions on Cybernetics, 2013, 43(2): 425-436.
- [18] Zheng Y Q, Sato I, Sato Y. Illumination and reflectance spectra separation of a hyperspectral image meets low-rank matrix factorization[C]. IEEE Conference on Computer Vision and pattern Recognition, 2015: 1779-1787.
- [19] Chen X. Intrinsic image decomposition of spectral images[D]. Nanjing: Nanjing University, 2017: 4-9.  
陈希. 光谱图像本质分解[D]. 南京: 南京大学, 2017: 4-9.
- [20] Dai Q H, Lin X, Xu C X, *et al.* Decomposition method and device for hyperspectral intrinsic image: CN104700109A[P]. 2015-06-10.  
戴琼海, 林星, 许晨雪, 等. 高光谱本征图像的分解方法及装置: CN104700109A[P]. 2015-06-10.
- [21] Gu Y F, Zhang Y. Feature extraction based on automatic subspace partition for hyperspectral images [J]. Remote Sensing Technology and Application, 2003, 18(6): 384-387.  
谷延锋, 张晔. 基于自动子空间划分的高光谱数据特征提取 [J]. 遥感技术与应用, 2003, 18(6): 384-387.
- [22] Su H J, Sheng Y H, Du P J. Study on auto-subspace partition for band selection of hyperspectral image [J]. Geo-Information Science, 2007, 9(4): 123-128.  
苏红军, 盛业华, 杜培军. 自动子空间划分在高光谱影像波段选择中的应用[J]. 地球信息科学, 2007, 9(4): 123-128.