

文章编号:1001-9014(2016)06-0731-10

DOI:10.11972/j.issn.1001-9014.2016.06.016

基于低秩表示和学习字典的高光谱图像异常探测

钮宇斌^{1,2,3}, 王斌^{1,2,3*}

(1. 复旦大学 电磁波信息科学教育部重点实验室, 上海 200433;
2. 北京师范大学 地表过程与资源生态国家重点实验室, 北京 100875;
3. 复旦大学 信息学院智慧网络与系统研究中心, 上海 200433)

摘要: 提出一种基于低秩表示和学习字典的高光谱遥感图像异常探测算法。相对于其它低秩矩阵分解方法如鲁棒主成分分析, 低秩表示方法更为契合高光谱图像的线性混合模型。该算法将低秩表示模型应用到高光谱图像异常探测问题上来, 引入表征背景信息的学习字典, 大大增强了低秩表示模型对初始参数的鲁棒性。仿真和实际高光谱数据的实验结果表明, 所提出的算法有效地提高了异常的探测率, 同时对初始参数具有较好的鲁棒性, 可以作为一种解决高光谱图像异常探测的有效手段。

关 键 词: 高光谱图像; 异常探测; 低秩矩阵分解; 低秩表示; 学习字典

中图分类号: TP751 **文献标识码:** A

Hyperspectral anomaly detection using low-rank representation and learned dictionary

NIU Yu-Bin^{1,2,3}, WANG Bin^{1,2,3*}

(1. Key Laboratory for Information Science of Electromagnetic Waves (MoE), Fudan University, Shanghai 200433, China;
2. State Key Laboratory of Earth Surface Processes and Resource Ecology, Beijing Normal University, Beijing 100875, China;
3. Research Center of Smart Networks and Systems, School of Information Science and Technology,
Fudan University, Shanghai 200433, China)

Abstract: This paper proposes an anomaly detection method based on low-rank representation and learned dictionary for hyperspectral imagery. The model of low-rank representation, which fits the linear mixing model of hyperspectral imagery more precisely compared with other low-rank decomposition algorithms such as robust principle component analysis (RPCA), was introduced to settle the anomaly detection problem for hyperspectral imagery. To improve its robustness to initialized parameters, a learned dictionary that represents only background information was adopted in the proposed method. Experiments on synthetic and real hyperspectral datasets illustrated that the proposed method is capable of improving detection results. Meanwhile, it is robust to initialized parameters and can be viewed as an effective technique to detect anomalies in hyperspectral imagery.

Key words: Hyperspectral imagery; anomaly detection; low-rank matrix decomposition; low-rank representation; learned dictionary

PACS: 84.40. Xb

引言

高光谱遥感图像具有光谱分辨率高、图谱合一

的特点, 在地物目标探测领域具有独特的优势, 可以应用于环境监测、军事侦察等领域。在实际情况下, 研究者往往很难获取目标类别的光谱特性。因此无

收稿日期: 2015-11-09, 修回日期: 2016-04-01

Received date: 2015-11-09, revised date: 2016-04-01

基金项目: 国家自然科学基金(61572133); 北京师范大学地表过程与资源生态国家重点实验室开放基金(2015-KF-01)

Foundation items: Supported by National Natural Science Foundation of China (61572133), Research Fund for the State Key Laboratory of Earth Surface Processes and Resource Ecology (2015-KF-01)

作者简介(Biography): 钮宇斌(1990-), 男, 浙江湖州人, 博士研究生, 主要从事高光谱图像目标探测的研究。E-mail: 12110720009@fudan.edu.cn

* 通讯作者(Corresponding author): E-mail: wangbin@fudan.edu.cn

需先验知识的高光谱图像异常探测算法在近年来得到了快速的发展^[1].

高光谱图像中的异常目标出现概率小,同时其光谱与周边背景光谱存在显著区别.传统的 RX 算法^[2]通过计算待探测像元与背景的马氏距离来进行异常探测,根据不同的背景样本的选取,RX 算法大致分为全局 RX (Global RX, GRX) 和邻域 RX (Local RX, LRX) 两类.传统的基于统计学模型的异常探测算法有两种缺陷,一是实际的高光谱遥感图像的背景并不完全服从高斯分布,二是背景协方差矩阵的计算过程中常常会被异常目标污染.

为了避免传统方法的上述缺陷,稀疏表示被应用到高光谱图像目标探测问题上来^[3].稀疏目标探测基于高光谱图像的线性混合模型,认为图像上的每一个像元可以稀疏地被一个含有目标光谱与背景光谱的过完备字典线性表示.利用目标分量与背景分量之差来判断一个像元是否属于目标.然而稀疏的方法主要用到了图像的光谱信息,在空间上使用的信息不足,因此当稀疏的方法直接应用到异常探测问题中时,往往难以取得令人满意的效果.不同于稀疏表示,协同表达认为背景像元可以被邻域协同表示,而异常不行,Q. Du 等人发展了基于协同表达的异常探测算法 (Collaborative-representation-based detector, CRD)^[4],取得了不错的效果.

低秩矩阵分解算法是近年来的研究热点之一.其主要思想是将一个矩阵分解为一个低秩矩阵和一个稀疏矩阵之和.在高光谱遥感领域,低秩矩阵分解已经得到了广泛的应用,比如降噪^[5]、图像恢复^[6]等.由于高光谱图像中的地物种类是有限的,我们可以认为其背景信息是低秩的,而异常由于其出现概率小,可以被认为是稀疏的,因此低秩矩阵分解算法可以应用到高光谱图像异常探测问题上来,利用分解得到的稀疏矩阵来进行异常探测.鲁棒主成分分析(Robust principle component analysis, RPCA)^[7]已经被用在高光谱图像的异常探测上来^[8].T. Zhou 等人在 RPCA 的模型上加入了高斯项^[9],从而开发了基于低秩模型和稀疏矩阵的异常探测算法 (Low-rank and sparse matrix based anomaly detector, LRaSMD)^[10].在 RPCA 的基础上,G. Liu 等人将 RPCA 发展到低秩表示 (Low-rank representation, LRR) 模型^[11],认为低秩的数据可以源自于多个子空间.相较 RPCA 而言,LRR 模型更为符合高光谱图像的线性混合模型.本文提出一种基于 LRR 的高光谱图像异常探测算法 (Low-rank representation-

based detector, LRRD),以期得到更为准确的异常探测结果.

然而,以上 LRR 算法对于初始参数的设置较为敏感,对应不同的高光谱图像,最优的参数选择往往是不同的,这在实际应用当中是一个显著的缺陷.在 LRR 模型中,需要用到一个字典矩阵,研究者往往将数据矩阵自身作为该字典^[11],此时 LRR 模型对权衡低秩矩阵和稀疏矩阵的因子十分敏感.本文用一个学习字典替换 LRR 中的字典.字典学习基于一个随机选择并且梯度下降的过程,因此该学习字典可以被认为只含有高光谱图像的背景信息,这使得 LRR 模型对参数更为鲁棒.值得指出的是,该学习字典已经成功应用在了高光谱图像稀疏目标探测领域^[12].模拟实验表明,在 LRR 模型上引入了学习字典之后,算法具有更高的鲁棒性,同时模拟数据实验与实际数据实验表明,所提出的算法具有最优的探测结果.

1 低秩表示

主成分分析 (Principle component analysis, PCA) 通过寻找子空间的线性模型来完成数据降维,可以有效地去除数据中的高斯噪声,然而当数据中存在比较大的噪声或者异常时,PCA 的效果就不够理想.针对这种情况,研究学者提出了 RPCA^[7],通过将一个具有低秩特性的矩阵分解为一个低秩矩阵和一个稀疏矩阵之和,其优化函数为:

$$\min_{L,S} \text{rank}(L) + \lambda \|S\|_0, \text{ s. t. } X = L + S, \quad (1)$$

其中 X 是数据矩阵, L 与 S 分别是低秩矩阵和稀疏矩阵, $\|\cdot\|_0$ 是 l_0 范数, 指矩阵中非零元素的个数, λ 是低秩矩阵和稀疏矩阵的权衡因子.然而,上述问题是非凸问题,研究者往往会将该问题松弛到以下优化问题:

$$\min_{L,S} \|L\|_* + \lambda \|S\|_1, \text{ s. t. } X = L + S, \quad (2)$$

其中 $\|\cdot\|_*$ 是核范数, 表示矩阵的奇异值之和; $\|\cdot\|_1$ 是 l_1 范数, 表示矩阵元素绝对值之和.

然而 RPCA 假设数据矩阵来源于一个子空间.区别于 RPCA, LRR 假设数据矩阵由多个子空间生成,其优化问题为:

$$\min_{L,S} \|Z\|_* + \lambda \|S\|_{2,1}, \text{ s. t. } X = DZ + S, \quad (3)$$

其中 $\|\cdot\|_{2,1}$ 是 $l_{2,1}$ 范数, 表示矩阵每一列的 l_2 范数之和.

增广的拉格朗日乘子法可以被用来求解上述问题,先转化为以下优化问题:

$$\min_{Z, E, J} \|J\|_* + \lambda \|S\|_{2,1}, \text{s. t. } X = DZ + S, Z = J \quad (4)$$

然后,通过最小化以下函数得到 LRR 的分解结果^[11]:

$$L = \|J\|_* + \lambda \|S\|_{2,1} + \text{tr}(Y_1^T(X - DZ - S)) + \text{tr}(Y_2^T(Z - J)) + \frac{\mu}{2}(\|X - DZ - S\|_F^2 + \|Z - J\|_F^2) \quad (5)$$

2 算法描述

2.1 高光谱图像低秩特性

根据线性混合模型,一个由 p 种地物端元构成的高光谱图像中的每一个像元可以由其端元光谱线性组成,其图像数据 $X \in \mathbf{R}^{L \times N}$ 可以被表示为:

$$X = EA \quad (6)$$

其中 L 是高光谱图像波段数, N 为高光谱图像的像元个数, $E = [e_1, e_2, \dots, e_p] \in \mathbf{R}^{L \times p}$ 与 $A = [a_1^T, a_2^T, \dots, a_p^T] \in \mathbf{R}^{p \times N}$ 分别表示端元矩阵和对应的丰度矩阵.

由上式可以得到, $\text{rank}(X) \leq \text{rank}(E) = p$. 由于一幅高光谱图像中的地物光谱种类是有限的, 因此在大多数情况下, $p \ll L$, 所以可以认为高光谱图像数据具有内在的低秩特性, 低秩矩阵分解算法可以有效地用在高光谱图像数据上.

高光谱图像中关于异常点的确切定义目前还没有达到一致, 在本文中, 把那些出现概率小, 光谱与其他背景有明显差异的点作为异常点. 假设 p 个端元中前 r 个端元出现概率高, 则作为图像的背景, 而后面的端元出现概率低, 则作为异常, 那么一个像元是否属于异常可以由下式表示:

$$x_i = \sum_{j=1}^p a_{ij} e_j = \sum_{j=1}^r a_{ij} e_j + \sum_{j=r+1}^p a_{ij} e_j \rightarrow \\ \begin{cases} a_{i,r+1} = a_{i,r+2} = \dots = a_{i,p} = 0, & \text{若 } x_i \text{ 是背景像元} \\ \dots, & \text{若 } x_i \text{ 是异常} \end{cases} \quad (7)$$

对于整个高光谱数据, 可以表示为:

$$X = E_b A_b + E_a A_a \quad (8)$$

其中, $E_b = [e_1, e_2, \dots, e_r] \in \mathbf{R}^{L \times r}$, $A_b = [a_1, a_2, \dots, a_r] \in \mathbf{R}^{r \times N}$ 分别是背景端元的光谱和对应的丰度, $E_a = [e_{r+1}, e_{r+2}, \dots, e_p] \in \mathbf{R}^{L \times (p-r)}$, $A_a = [a_{r+1}^T, a_{r+2}^T, \dots, a_p^T] \in \mathbf{R}^{(p-r) \times L}$ 分别是异常的光谱和对应的丰度.

上式中的第一部分表示背景, $r < p \ll L$, 因此是低秩的, 而第二部分由于异常的出现概率小, 因而是稀疏的. 因此低秩矩阵分解算法可以将高光谱图像

数据分解为低秩矩阵和稀疏矩阵两部分, 并且有效地将背景信息和异常信息分离开来. 然后将基本的异常探测算法应用到稀疏矩阵中就可以得到异常探测的结果. 与此同时, 由于上式中的低秩项的表达式与 LRR 模型相契合, 因此当已知背景的端元矩阵 E_b 时, 可以利用式(3)中的 LRR 优化模型, 将高光谱图像的异常信息分离出来, 从而更为有效地进行异常探测.

2.2 字典学习

在以往的工作中, 研究者往往将数据本身作为 LRR 中的字典^[11], 当使用了一个适当大小的参数来权衡低秩矩阵与稀疏矩阵时, 可以得到比较理想的分解结果. 然而这种方法存在如下问题: 1) 当用自身数据作为字典时, 在式(3)中, 其优化的表达矩阵的 Z 大小是 $N \times N$, 在高光谱数据中, N 是指像素的个数, 因此 Z 将会是一个尺寸非常大的矩阵, 会给计算带来更多地开销; 2) 算法的有效与否与权衡因子 λ 密切相关, 当 λ 取值过大时, 稀疏的约束过多可能导致异常的信息进入到低秩矩阵中去, 从而异常的探测率可能会受到影响, 而当 λ 取值过小时, 一些背景信息可能会进入到稀疏矩阵中去, 从而可能会提高虚警率.

为了解决上述问题, 本文在 LRR 中引入了学习字典^[13]的概念. 首先利用高光谱图像数据得到学习字典, 然后将学习字典带入 LRR 模型中的字典, 最后将基本的异常探测算法用在稀疏矩阵上得到探测结果. 为了更好地将异常信息分离出来, 结合稀疏表示和低秩表示的特点, 所需要的学习字典应尽可能只包含背景的光谱. 本文采用了一种基于随机选取并且梯度迭代的字典学习算法. 对于图像上的每一个像元 x , 可以表示为:

$$x = D\alpha + v \quad (9)$$

其中 D 表示字典矩阵, α 是对应的稀疏向量, v 是误差项.

首先随机生成初始字典 D . 当已知字典矩阵时, 稀疏向量可以通过求解以下优化问题得到:

$$\hat{\alpha} = \arg \min \|\mathbf{x} - D\alpha\|_2^2 + \gamma \|\alpha\|_1. \quad (10)$$

字典矩阵可以通过如下所示的梯度算法进行迭代更新:

$$D^{(n+1)} = D^{(n)} - \mu \sum_{i=1}^M (D^{(n)} \alpha_i - x_i) \alpha_i^T \quad (11)$$

其中 μ 是每次迭代过程中的步长, M 是每次迭代过程中选取的样本个数. 在学习过程中, 每次从图像中随机挑选出 M 个样本, 利用这 M 个样本通过式

(10) 与(11)不断更新字典.

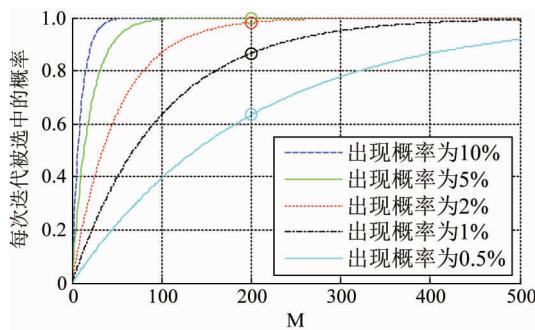


图 1 每次迭代不同占比地物样本被选到的概率

Fig. 1 Probabilities of endmembers with different occupations being chosen in iteration

图 1 为每次迭代过程中不同占比的地物样本被选到的概率, 其概率 P_i 可以表示为:

$$P_i = 1 - (1 - \rho_i)^M \quad (12)$$

其中 ρ_i 为不同地物端元的出现概率, 由于异常出现概率小(一般小于 0.5%), 在迭代过程中被选到的概率低, 在学习过程中无法被充分学习得到, 而背景光谱出现概率高, 可以准确地被学习得到, 因此在这个学习过程中, 可以认为学习得到的光谱仅仅表示背景信息. M 决定了每次迭代中不同占比的地物样本被选到的概率, 在实验中 M 固定为 200. 值得一提的是, 这种迭代更新的方法可能会存在局部极小的问题, 但是已有的实验结果表明, 所学习得到的原子能够与端元的光谱相匹配^[13]. 不同于其他的学习字典如 K-SVD^[14], 本文用到的学习字典实际上是一个表示背景的非完备字典^[12]. 当把该字典用在 LRR 模型上时, 可以有效地提高低秩表示算法对初始参数设置的鲁棒性, 更好地将异常信息从高光谱图像中分离到稀疏矩阵中去. 具体的学习过程如下所示:

算法: 字典学习

输入: 观测数据矩阵 $X \in \mathbb{R}^{L \times N}$, 字典原子个数 n
输出: 学习字典 $D \in \mathbb{R}^{L \times n}$

步骤 1. 随机初始赋值字典矩阵 D

步骤 2. 执行以下循环:

2a) 从高光谱图像中随机选择 M 个像元;

2b) 对选取的 M 个像元, 利用式(10)求出各自对应的稀疏向量 $\alpha_1, \alpha_2, \dots, \alpha_M$;

2c) 用式(11)更新迭代学习字典;

2d) 归一化字典矩阵;

2e) 当满足最大迭代次数时, 跳出循环.

步骤 3. 输出结果.

2.3 算法流程

图 2 描绘了所提出算法的流程图, 其主要步骤如下:

步骤 1. 将一幅三维的高光谱图像数据变为二维图像数据 $X \in \mathbb{R}^{L \times N}$.

步骤 2. 利用字典学习算法得到一个只包含背景的字典矩阵 D .

步骤 3. 通过 LRR 算法将 X 分解为一个低秩矩阵和稀疏矩阵之和.

步骤 4. 将基本的异常探测算法用在稀疏矩阵上得到最终的探测结果. 本文实验中利用 GRX 作为这一步骤的异常探测算法.

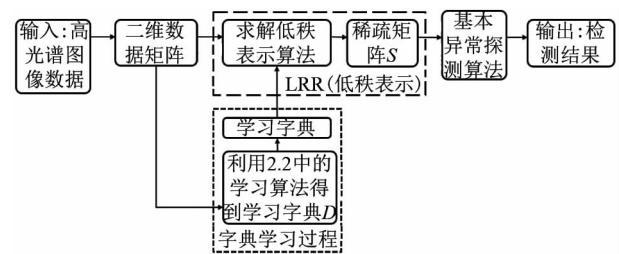


图 2 算法流程图

Fig. 2 Framework of the proposed method

3 实验结果与讨论

3.1 模拟数据实验

采用在高光谱图像中埋入异常点的方式构造模拟实验数据, 首先研究了学习字典对 LRR 模型的影响, 然后将本文提出的算法 LRRD 与传统的 GRX 算法、近期提出的基于协同表达的 CRD 算法和另外两种基于低秩矩阵分解的算法 RPCA 与 LRASMD 进行比较, 来测试所提出算法的有效性. 直观的二维探测结果图、接收者操作特性曲线 (Receiver operating characteristic, ROC)^[15] 与 ROC 曲线下面积 (Area under ROC curve, AUC) 用作实验中探测性能的评价标准. 与此同时我们记录了各个算法的运算时间以衡量其复杂度, 所有实验的软硬件环境为 Intel (R) Xeon(R) E5504 CPU 2.00 GHz, 24 GB 内存和 Windows 7 及 Matlab 8.1.0.604 R2013a.

3.1.1 模拟实验数据

模拟实验数据采用了由 HyMap 机载高光谱探测仪于 2006 年 7 月 4 日在美国马瑟诸塞州一块区域上空拍摄得到的高光谱图像数据^[16]. 该数据图像大小为 280×280 , 具有 126 个波段, 为了研究背景对提出算法的影响, 在其中截取了 150×150 的两个小块, 分别对应了简单的背景和复杂的背景, 如图 3

所示.三条异常光谱被用到模拟实验中,其中 F1、F2 和 V1 分别对应了红色棉布、黄色尼龙和汽车光谱.由于异常点在实际图像中的分布是不规律的,为了更好地模拟实际情况,我们在图像中随机生成了 25 个位置,利用式(13)的方式在这 25 个位置上各埋入一个异常点,其丰度分别为 0.04、0.08、…、1. 图 4 显示了所用到的子块和对应的地物真实. 埋入异常点的像素光谱 z 由下式计算得到:

$$z = f \cdot t + (1 - f) \cdot b \quad , \quad (13)$$

其中 f 为异常的丰度, t 为异常光谱, b 为当前像元的光谱.



图 3 HyMap 数据集的 RGB 合成图

Fig. 3 RGB composite of HyMap dataset

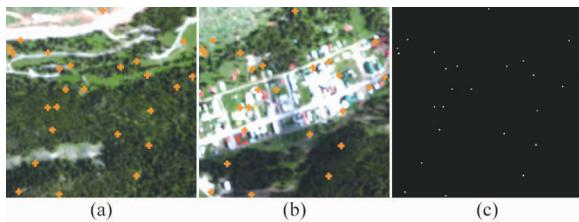


图 4 模拟数据 (a) 简单背景,(b) 复杂背景,(c) 地物真实
Fig. 4 Sub-images with (a) simple background, (b) complex background, and (c) ground-truth

3.1.2 初始参数对提出算法的影响

许多算法对初始参数的设置较为敏感. 对于 CRD 算法来说, 窗口大小的选择十分重要; 对于 LRaSMD 来说, 需要预先设置比较合理的低秩矩阵的秩和稀疏矩阵的稀疏度; 对于 RPCA 来说, 低秩部分与稀疏部分的权衡因子的选择对结果有很大影响. 本文提出的 LRRD 主要有两个参数需要预先设置: 权衡因子 λ 和学习字典的原子个数 n . 图 5 与图 6 表示在不同的背景中, 埋入不同的异常光谱, 利用提出的算法在不同的初始参数设置情况下的 AUC 面积. 从图中可以看出, 不同的参数下获得的 AUC 面积呈现一个平坦的曲面, 这说明所提出的算法具有较好的鲁棒性. 其中图 6(c) 的波动最大, 其可能的原因是图 6(c) 中用的异常光谱是汽车光谱, 而背景的村镇中可能存在其他的汽车的光谱对探测产生

了一定的干扰. 尽管如此, 得到的 AUC 还是令人满意的($AUC > 0.9$).

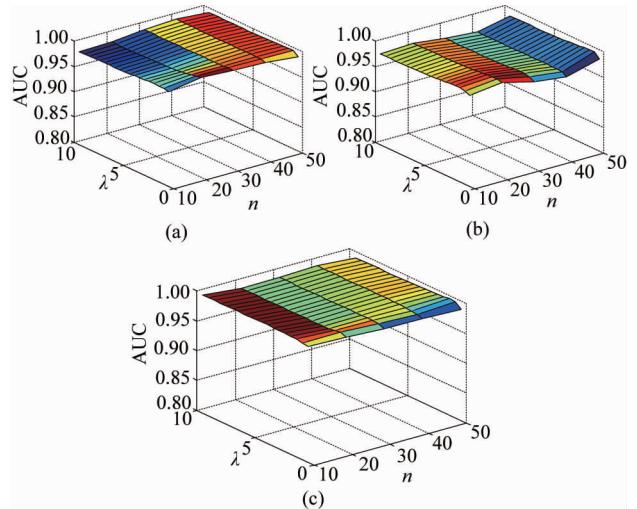


图 5 基于简单背景的不同参数下的探测结果 (a) F1,(b) F2,(c) V1

Fig. 5 Results with different parameters under simple background (a) F1, (b) F2, (c) V1

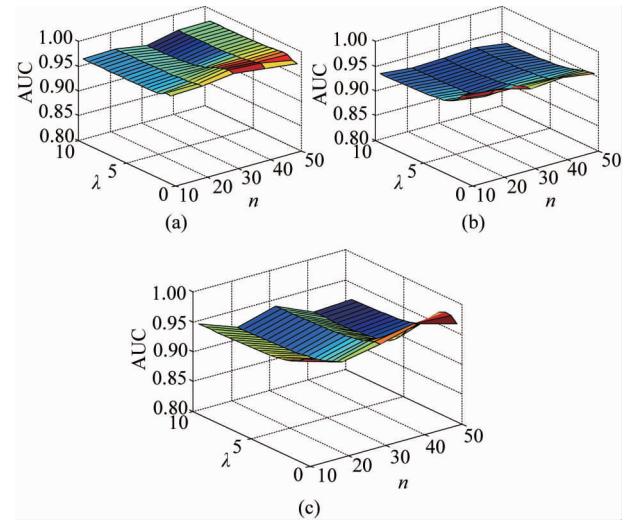


图 6 基于复杂背景的不同参数下的探测结果 (a) F1,(b) F2,(c) V1

Fig. 6 Results with different parameters under complex background (a) F1, (b) F2, (c) V1

为了说明学习字典的引入对提高探测性能的影响, 我们将提出的算法与利用自身数据作为字典的 LRR 算法进行了比较. 此时统一学习字典的原子个数为 30. 图 7 与图 8 是在不同的权衡因子下的比较. 可以看出, 利用学习字典, 得到的 AUC 面积更为稳定, 且普遍要高于利用自身数据作为字典的情况. 这说明学习字典的引入对于提升算法对权衡因子的鲁棒性很有作用. 与此同时, 由于

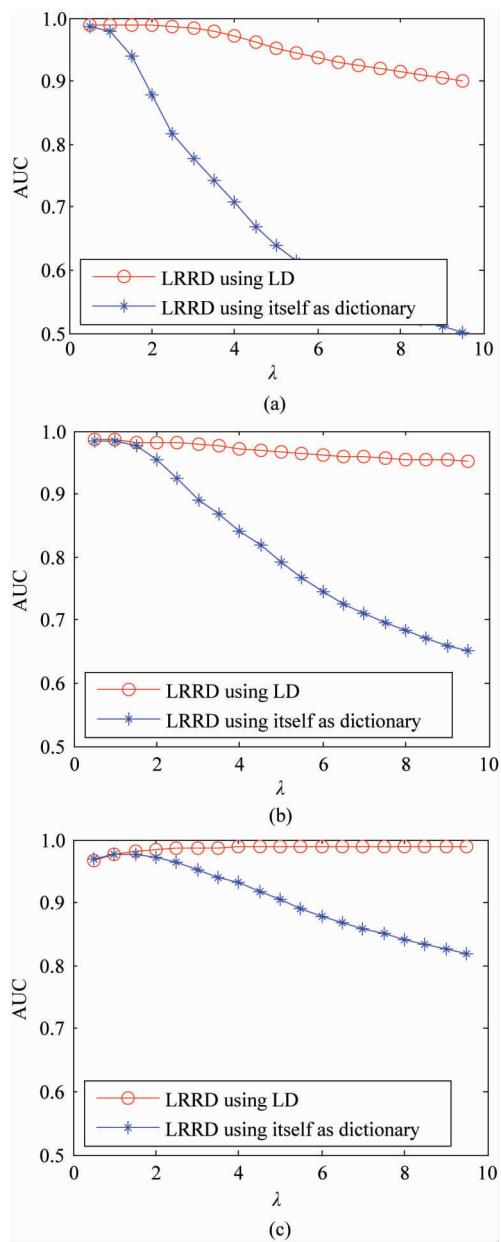


图 7 基于简单背景的不同权衡因子的 AUC 面积
(a) F1, (b) F2, (c) V1

Fig. 7 AUC with different tradeoff parameter under simple background (a) F1, (b) F2, (c) V1

学习字典的数据量要远小于原始矩阵的数据量,所需要的运算开销也大大减少了。利用自身数据字典的 LRR 算法的运算开销为 88.34 s,利用学习字典的 LRR 算法的运算开销为 26.21 s。然而提出的算法还需要添加学习的时间。学习的主要开销在优化式(10)的过程,通过使用 Matlab 工具包 spams^[17],该优化速度大大提升了,当迭代次数为 1 000 时,学习的时间为 32.43 s,因此提出的算法总耗时为 58.64 s,仍快于利用自身数据作为字典

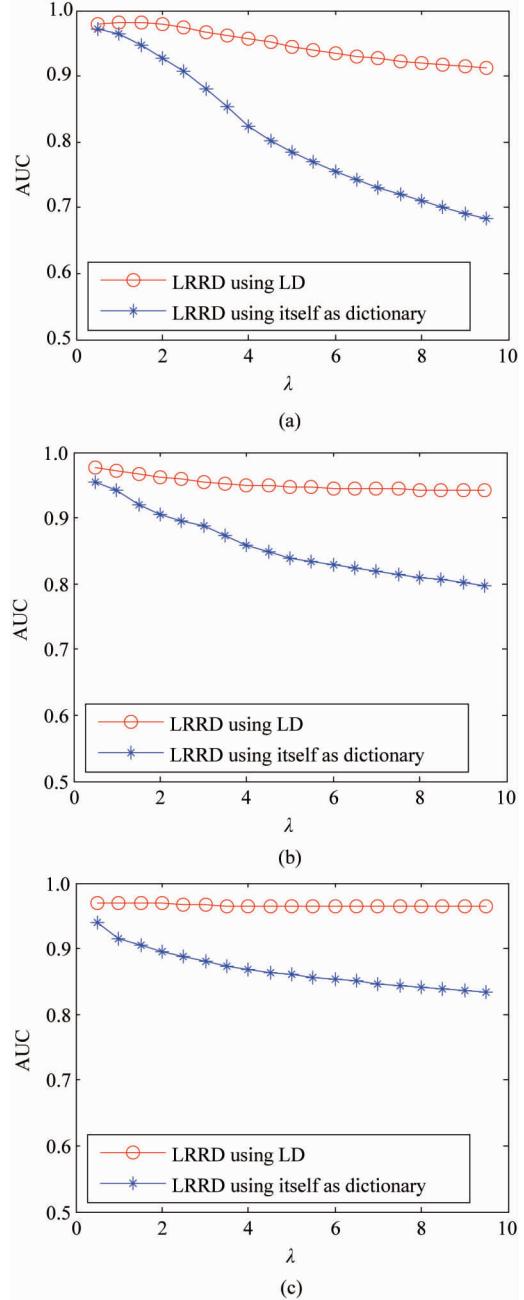


图 8 基于复杂背景的不同权衡因子的 AUC 面积
(a) F1, (b) F2, (c) V1

Fig. 8 AUC with different tradeoff parameter under complex background (a) F1, (b) F2, (c) V1

的 LRR 算法。之后关于提出的 LRRD 算法的运算时间分析均包括了字典学习的过程。

由于所提出算法具有较好的鲁棒性,之后的实验我们统一将学习字典的原子个数设定为 30,权衡因子设定为 1。

3.1.3 探测结果比较

将所提出的 LRRD 算法与传统的 GRX 算法、基于协同表达的异常探测算法 CRD 和另外两种基于

低秩矩阵分解的算法 RPCA 和 LRaSMD 进行比较, 来测试所提出算法的有效性。其中为了得到其他对比算法的最优结果, 我们将 CRD 的内外窗分别设为 11×11 与 15×15 , LRaSMD 的秩和稀疏度分别设为 8 与 0.3; 由于 RPCA 对权衡因子的选择十分敏感, 所以对于不同的情况我们尝试了多种选择, 并且选出其中最好的情况来进行比较。

图 9 与图 10 分别是各个算法在简单背景和复杂背景下的二维探测结果, 其中的二值化图像是采用了虚警率为 10^{-3} 时的探测结果, 其中图中探测得到的点数越多说明效果越好。图 11 与图 12 是对应的 ROC 曲线, 从图像中可以直观地看出, LRRD 具有更高的探测率。除此之外, 在简单背景中, RPCA 与 LRaSMD 拥有较好的探测率, 而在复杂背景中, 这两种基于低秩矩阵分解算法的效果就不够理想, 这可能因为这两种算法的假设是高光谱图像出自一个子空间。相较而言, LRRD 假设图像出自多个子空间, 使得 LRRD 在复杂背景中也有较好的探测结果。CRD 则用了较为充分的邻域信息, 因此在简单和复杂背景情况下有着近似的结果。

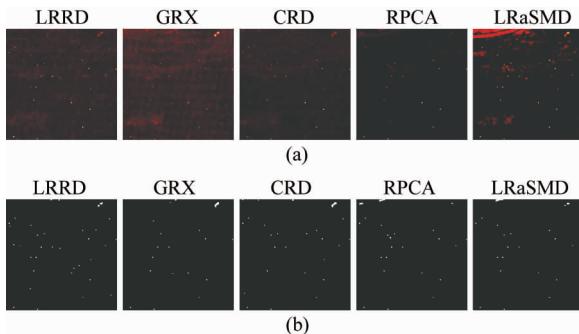


图 9 基于简单背景的探测结果 (a) 二维探测图,(b) 二值化探测结果

Fig. 9 Detection results under simple background (a) 2-D display, (b) binary results

为了避免某种特定的随机位置的影响, 将实验重复了 20 次, 即采用了 20 组不同的随机位置, 表 1 是当虚警率为 10^{-2} 时的探测率结果。从表中也可以

表 1 当虚警率为 0.01 时的探测率(20 次重复)

Table 1 Average detection rates when PFA equals to 0.01 (20 repetitions)

不同算法	简单背景			复杂背景		
	F1	F2	V1	F1	F2	V1
LRRD	0.946 ± 0.027	0.906 ± 0.047	0.816 ± 0.057	0.826 ± 0.058	0.800 ± 0.670	0.762 ± 0.073
GRX	0.682 ± 0.009	0.644 ± 0.012	0.522 ± 0.020	0.518 ± 0.028	0.510 ± 0.022	0.478 ± 0.042
CRD	0.866 ± 0.072	0.846 ± 0.086	0.776 ± 0.079	0.798 ± 0.072	0.778 ± 0.081	0.742 ± 0.098
RPCA	0.930 ± 0.018	0.864 ± 0.020	0.456 ± 0.027	0.594 ± 0.144	0.572 ± 0.121	0.384 ± 0.077
LRaSMD	0.852 ± 0.029	0.790 ± 0.069	0.530 ± 0.045	0.630 ± 0.119	0.552 ± 0.048	0.424 ± 0.132

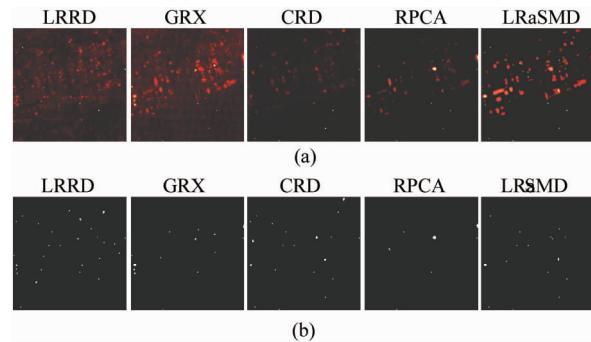


图 10 基于复杂背景的探测结果 (a) 二维探测图,(b) 二值化探测结果

Fig. 10 Detection results under complex background (a) 2-D display, (b) binary results

看出, 所提出的 LRRD 算法具有最高的探测率。表 2 是 20 组实验各自的运算时间, LRRD 的运算时间比 CRD 少, 与 LRaSMD 相当。

表 2 各算法运算时间(20 次重复)

Table 2 Execution time of different methods on synthetic dataset (20 repetitions)

运算时间/s	LRRD	GRX	CRD	RPCA	LRaSMD
简单背景	32.43 ± 0.15	5.37 ± 0.16	42.39 ± 0.70	16.68 ± 0.27	36.03 ± 0.40
复杂背景	33.48 ± 0.37	5.40 ± 0.33	42.48 ± 1.10	18.29 ± 0.23	35.98 ± 0.51

3.2 实际数据实验

一幅由 HYDICE 机载高光谱成像光谱仪在城市上空拍摄得到高光谱遥感图像被用作实际数据, 如图 13 所示, 该图像大小为 307×307 , 去除噪声波段和水吸收波段之后还剩下 160 个波段, 然而其中只有右上角由矩形框出的子图像有着与其对应的地物真实, 因此利用这一大小为 80×100 的小块进行实际数据的异常探测。同样将所提出的 LRRD 算法与 GRX、CRD、RPCA 和 LRaSMD 进行了比较。依照 3.1.2 节中的内容所述, LRRD 中字典原子个数设为 30, 权衡因子设为 1. 对比法则通过尝试选择最优的参数, 其中 CRD 的内外窗口的大小分别选取为 7×7 与 15×15 , RPCA 用到的权衡因子为 0.015, LRaSMD 初始设置的秩与稀疏度分别为 8 和 0.3.

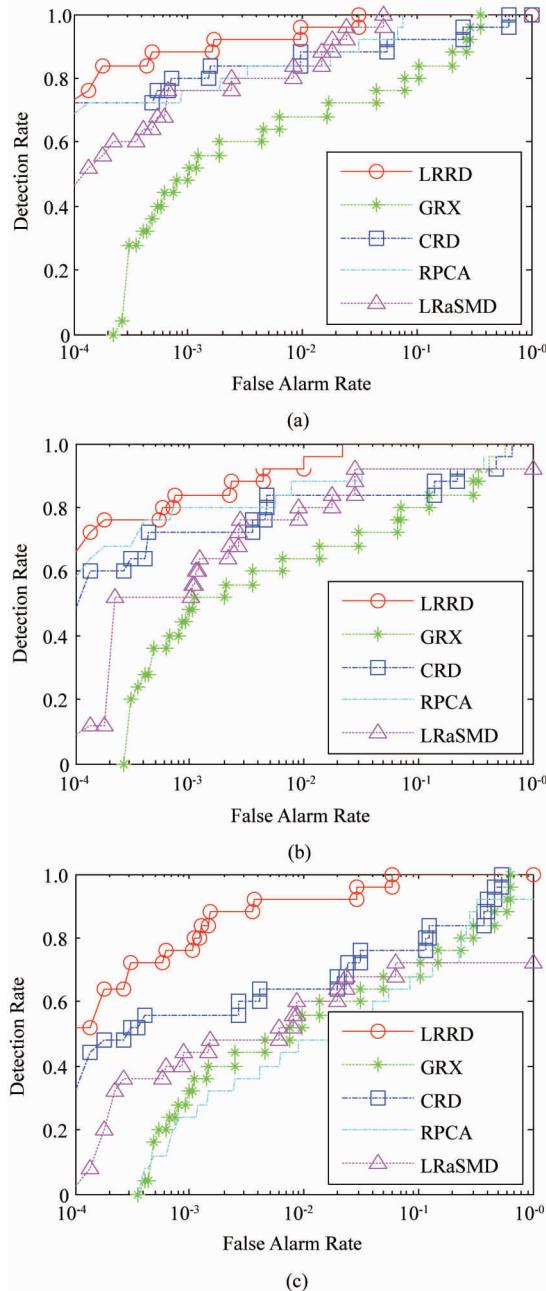


图 11 基于简单背景的 ROC (a) F1, (b) F2, (c) V1
Fig. 11 ROC under simple background (a) F1, (b) F2, and (c) V1

图 14 显示的是各个算法进行异常探测的结果, 其中二值化的图像是令虚警率为 10^{-3} 时得到的结果。可以看出, 所提出的 LRRD 具有最高的探测率。图 15 是对应的 ROC 曲线, LRRD 具有最好的结果。在 ROC 曲线在虚警率很低的位置, LRRD 与 RPCA 和 CRD 方法结果近似, 可能是因为低秩矩阵分解算法过程中, 往往也会将一些较大的噪声信息分到稀疏矩阵当中去, 从而影响探测结果。而这个 HYDICE 图像具有较高的条带噪声, 因此在虚警率低的位置

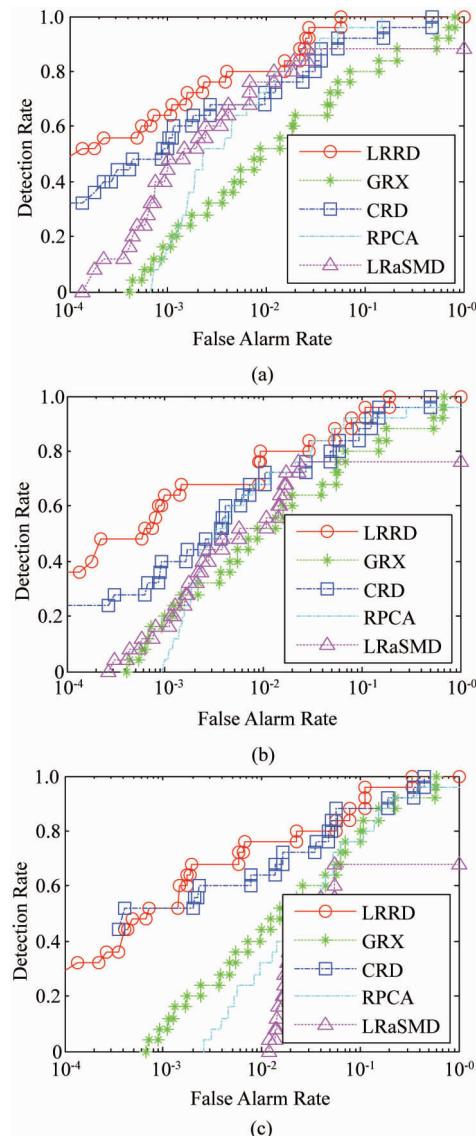


图 12 基于复杂背景的 ROC (a) F1, (b) F2, (c) V1
Fig. 12 ROC under complex background (a) F1, (b) F2, and (c) V1

几种低秩的算法表现出相似的结果。表 3 是对应的 AUC 面积和运算时间, 所提出的 LRRD 算法具有最高的 AUC, 计算时间要小于 CRD 和 LRaSMD.

表 3 不同算法的 AUC 面积和运算时间

Table 3 AUC and execution time of different methods

高光谱数据	LRRD	GRX	CRD	RPCA	LRaSMD
AUC	0.998 8	0.987 2	0.996 1	0.979 3	0.888 7
运算时间(s)	15.67	0.87	33.23	6.53	18.81

3.3 实验小结

模拟与实际数据实验均体现了所提出的 LRRD 算法在异常探测方面的良好效果。总得来说, LRRD

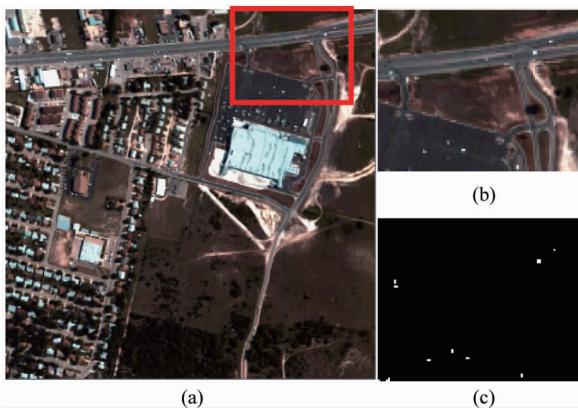


图 13 HYDICE 数据集 (a) RGB 彩色图(波段为 55,31,22),(b) 数据区域,(c) 地物真实

Fig. 13 HYDICE dataset (a) RGB composite (55, 31, 22), (b) region of interest, (c) ground-truth

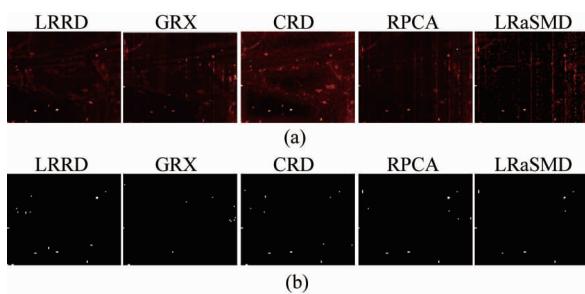


图 14 HYDICE 探测结果 (a) 二维探测图,(b) 二值化探测结果

Fig. 14 Detection results of HYDICE dataset (a) 2-D display, (b) binary results

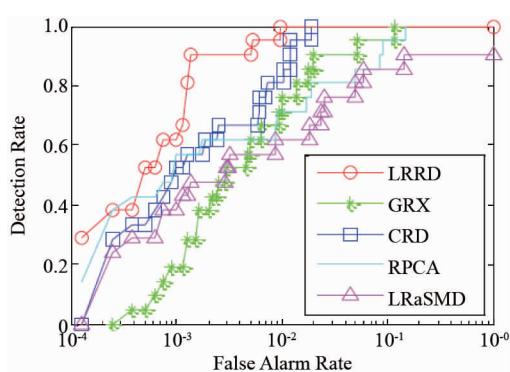


图 15 ROC 曲线

Fig. 15 ROC curve

具有以下几个特点:

1) 探测有效性: 低秩矩阵分解算法可以将一个具有低秩特性的高光谱遥感图像数据分解为一个表示背景的低秩矩阵和一个表示异常的稀疏矩阵之和, 可以较好地用在高光谱图像异常探测方面上。相

比于其它低秩矩阵分解算法, LRR 模型更加契合高光谱图像的线型混合模型, 采用 LRR 算法可以得到更优的探测效果。

2) 算法鲁棒性: 传统的 LRR 模型利用自身数据矩阵作为低秩项的字典, 对于初始参数的设置较为敏感。本文提出的算法在 LRR 模型的基础上引入了仅包含背景光谱信息的学习字典, 能更好地将异常信息从高光谱图像中分离出来, 实现了高光谱图像中具有低秩特性的背景与小概率出现的异常之间更为有效的分离, 提高了算法对初始参数的鲁棒性。

3) 高计算效率: 通过引入学习字典, 有效地降低了低秩表示算法的计算开销, 使得所提出的 LRRD 更具有实际应用的意义。

4 结论

针对全局光谱异常, 提出了一种基于低秩表示和学习字典的高光谱遥感图像异常探测算法。通过低秩表示, 来挖掘高光谱图像内在的低秩特性, 将二维的高光谱图像数据矩阵分解为表征背景的低秩矩阵和表征异常的稀疏矩阵两个部分, 然后将传统的 RX 算法用在稀疏矩阵上得到最终的探测结果。同时, 我们在低秩表示过程中引入了学习字典, 来提高算法对背景信息与异常信息之间的有效分离, 并提高了算法对初始参数的鲁棒性, 降低了计算的开销。与同类算法相比, 本文提出的算法具有更高的异常探测率, 也更具有实际应用的意义。

References

- [1] Chang C I, Chiang S. Anomaly detection and classification for hyperspectral imagery [J]. *IEEE Trans. Geosci. Remote Sens.*, 2002, **40**(6):1314–1325.
- [2] Reed I S, Yu X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution [J]. *IEEE Trans. on Acoustics, Speech and Signal Process.*, 1990, **38**(10): 1760–1770.
- [3] Chen Y, Nasrabadi N M, Tran T D. Sparse representation for target detection in hyperspectral imagery [J]. *IEEE J. Sel. Topics Signal Process.*, 2011, **5**(3):629–640.
- [4] Li W, Du Q. Collaborative representation for hyperspectral anomaly detection [J]. *IEEE Trans. Geosci. Remote Sens.* 2015, **53**(3):1463–1474.
- [5] Zhao Y, Yang J. Hyperspectral image denoising via sparse representation and low-rank constraint [J]. *IEEE Trans. Geosci. Remote Sens.* 2015, **53**(1):296–308.
- [6] Zhang H, He W, Zhang L, et al. Hyperspectral image restoration using low-rank matrix recovery [J]. *IEEE Trans. Geosci. Remote Sens.*, 2014, **52**(8):4729–4743.
- [7] Candès E J, Li X, Ma Y, et al. Robust principal component analysis [J]. *J. ACM*, 2011, **58**(3):1–37.
- [8] Chen S, Yang S, Kalpakis K, et al. Low-rank decomposi-

- tion-based anomaly detection[C]. In *Proc. SPIE Def., Secur., and Sens., International Society for Optics and Photonics*, 2013, p. 87430N.
- [9] Zhou T, Tao D. Godec: Randomized low-rank & sparse matrix decomposition in noisy case[C]. In *Proc. 28th ICML*, 2011, pp. 33–40.
- [10] Sun W, Liu C, Li J, et al. Low-rank and sparse matrix decomposition-based anomaly detection for hyperspectral imagery[J]. *J. Appl. Remote Sens.* 2014, **8**(1):1–18.
- [11] Liu G, Lin Z, Yan S, et al. Robust recovery of subspace structures by low-rank representation [J]. *IEEE Trans. Pattern Anal. Mach. Intell.* 2013, **35**(1):171–184.
- [12] Niu Y, Wang B. Hyperspectral target detection using learned dictionary[J]. *IEEE Geosci. Remote Sens. Lett.*, 2015, **12**(7):1531–1535.
- [13] Charles A S, Olshausen B A, Rozell C J. Learning sparse codes for hyperspectral imagery[J]. *IEEE J. Sel. Topics Signal Process.* 2011, **5**(5):963–978.
- [14] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Trans. Signal Process.* 2006, **54**(11):4311–4322.
- [15] Kerekes J. Receiver operating characteristic curve confidence intervals and regions [J]. *IEEE Geosci. Remote Sens. Lett.*, 2008, **5**(2):251–255.
- [16] SnyderD, Kerekes J, Fairweather I, et al. Development of a web-based application to evaluate target finding algorithms[C]. In *Proc. IEEE IGARSS*, 2008, **2**:915–918.
- [17] Mairal J, Bach F, Ponce J, et al. Online learning for matrix factorization and sparse coding[J]. *J. Mach. Learn. Res.* 2010, **11**:19–60.