

非负谱稀疏表示的高光谱成像中的异常检测

韦道知, 黄树彩, 赵岩, 庞策

(空军工程大学 防空反导学院, 陕西 西安 710051)

摘要: 针对高光谱异常检测提出了一种新型的非负稀疏表示(NSR)模型。其核心思想是背景像素可以近似地表示为其周围邻域的稀疏线性组合, 而异常像素不能。算法中稀疏向量的非负性和一对一约束具有物理意义以及更好的辨别能力。为了排除在背景字典中呈现的潜在异常像素, 修剪与中心像素类似的原子, 然后通过非负正交匹配追踪(NOMP)算法求解 NSR 模型, 并将重建误差直接用于确定异常像素。最后, 通过实际的高光谱数据集的实验结果与现有的算法进行比较, 证明了所提出的算法的有效性。

关键词: 异常检测; 非负稀疏表示; 协作表示; 高光谱图像

中图分类号: TP75 **文献标志码:** A **DOI:** 10.3788/IRLA201645.S223001

Non-negative sparse representation for anomaly detection in hyperspectral imagery

Wei Daozhi, Huang Shucui, Zhao Yan, Pang Ce

(Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China)

Abstract: A novel non-negative sparse representation (NSR) model was proposed for hyperspectral anomaly detection. The key idea was that a background pixel can be approximately represented as a sparse linear combination of its surrounding neighbors, while an anomalous pixel cannot. The non-negativity and one-to-one constraints on the sparse vector were imposed for physical meaning and better discrimination power of the algorithm. In order to exclude the potential anomalous pixels presented in the background dictionary, the atoms which were similar to the center pixel was pruned. Then the NSR model was solved by non-negative orthogonal matching pursuit (NOMP) algorithm, and the reconstruction errors were directly used for determining the anomalies. Finally, experimental results on real hyperspectral data set demonstrate the effectiveness of the proposed algorithms by comparing it with state-of-the-art algorithms.

Key words: anomaly detection; non-negative sparse representation; collaborative representation; hyperspectral imagery

收稿日期: 2016-07-06; 修订日期: 2016-08-05

基金项目: 国家自然科学基金(61603410)

作者简介: 韦道知(1977-), 男, 讲师, 博士, 主要从事空天信息智能处理方面的研究。Email: superwsw2012@163.com

0 引言

目标检测和异常检测(AD)是高光谱图像(HSI)的两个重要应用。HSI 提供了关于不同对象的光谱和空间分布的丰富信息,允许更复杂的光谱空间模型用于更准确地检测目标。与目标检测不同,没有关于目标的频谱的先验信息可用于异常检测。因此,异常被检测为其光谱特征明显不同于其空间相邻像素的像素。由于空间分辨率的限制,子像素目标是异常检测的基本挑战。

人们已经提出了几种经典的异常检测算法。Reed-Xiaoli(RX)检测器^[1]被认为是异常检测的基准算法,它测试像素与其周围邻域之间的 Mahalanobis 距离来检测异常。在经典 RX 算法中,假设局部背景可以由高斯分布表示,然而,高斯分布假设经常被侵犯,特别是当局部背景包含几种不同种类的材料时。已经做出了大量的努力来解决这个问题。被称为核心 RX(KRX)算法^[2]的 RX 算法的非线性版本将原始数据映射到高维特征空间,其中 HSI 数据是高斯的。支持向量数据描述(SVDD)检测器^[3-4]包含非参数背景模型,是一种数据驱动的方法,避免关于局部背景的先分布假设。

最近,SR 已成功应用于 HSI 中的目标检测^[5-7]。这些算法将 HSI 场景中的每个像素表示为训练样本的稀疏线性组合,然后利用重建误差来确定异常。然而,其需要通常难以获得的目标光谱特性的现有知识。基于协作表示(CR)^[8]的检测器不是利用训练样本的小子集,而是使用所有训练样本来协作地表示中心像素。代替采用残差,局部光谱和空间稀疏性发散合并以检测异常^[9]。用于异常检测的背景联合稀疏表示(BJSR)模型^[10]使用字典学习方法来自适应地选择局部背景的最具代表性的背景基础。

受这些想法的启发,文中提出一种新的非负稀疏表示模型用于异常检测,没有任何分布假设。基本思想是背景像素位于由其局部背景字典中呈现的端点所跨越的低维子空间中,并且因此可以近似地表示为其邻居的稀疏线性组合,而异常像素不能。因此,对稀疏向量的非负性和一对一约束被强加以物理意义。此外,引入归一化和集中化以改善非负正交匹配追踪(NOMP)的行为,并且修剪原始背景字典以

排除潜在异常像素。显然,所提出的算法是子像素异常检测方法。该算法的主要优点是即使在背景字典中包括异常像素时也能够检测异常。

论文如下。CR 检测器简要介绍在第二部分。建议的 NSR 检测器在第三节中描述。参数优化和检测性能评价的实验如第四节所示。最后,第五节得出结论。

1 AD 的协同表示

CR 算法使用局部背景字典中的所有原子来协作表示测试样本。它被证明对于异常检测非常有效^[8]。在 CR 中,采用滑动矩形双窗策略,如图 1 所示。该策略在防止一些潜在异常像素在本地背景字典中混合方面非常有效。假设 y 是未知的测试样品,其中内部窗口(大小为 $w_{in} \times w_{in}$)和外部窗口(大小 $w_{out} \times w_{out}$)为中心, A 是本地背景字典。 A 中的元素 $\{a_i\}_{i=1,2,\dots,s} \in A^n$ 是内部和外部窗口之间的像素的训练样本。 $s(w_{out}^2 - w_{in}^2)$ 是所选样本的数量, n 是可用频带的数量。因此,字典 A 适应于每个测试像素的局部统计。




图 1 滑动矩形双窗

Fig.1 Illustration of the sliding rectangular dual window

对于异常像素,将在 A 中难以找到良好的匹配,因为在外窗口区域中不包含任何异常像素。因此,其光谱不能用 A 中原子表示。因此,笔者可以假设背景像素可以被线性地表示为 A 中原子的组合,而异常像素不能。然后异常检测的假设检验可以表示为:

$$H_0: y = A\alpha + e, \text{ anomaly absent}$$

$$H_1: y \neq A\alpha + e, \text{ anomaly present} \quad (1)$$

式中: α 为一个向量,其条目是相应 A 原子的丰度^[5], e 表示误差项。

为了使最小二乘解更稳定,提出了对最小二乘

法施加 Tikhonov 正则化^[11]。目的是寻找相应的有效向量 α 使得 $\|y-A\alpha\|_2^2$ 最小化并同时满足限制条件, 即 $\|\alpha\|_2^2$ 使得下式最小化:

$$\min_{\alpha} \|y-A\alpha\|_2^2 + \lambda \|\alpha\|_2^2 \quad (2)$$

式中: λ 为拉格朗日因子。

正则化最小二乘问题(2)被转化为下列问题:

$$\hat{\alpha}=(A^T A+\lambda I)^{-1} A^T y \quad (3)$$

然后,重建误差直接用于确定异常。残差是:

$$r=\|y-A\hat{\alpha}\|_2 \quad (4)$$

如果 r 大于一个给定的阈值, 那么 y 被标记为异常像素。

2 AD 的非负稀疏表示

在此节中,提出了一种新的基于 NSR 的算法用于异常检测。它是在线性混合模型(LMM)上建模^[12], 并通过 NOMP 算法求解。首先,NSR 模型建立在物理意义上。第二,采取有效的预处理以改善 NOMP 的行为。最后,根据线性表示误差修剪背景字典中的潜在异常像素。

2.1 NSR 模型

基于线性混合模型,每个测试样本可以表示为场景中呈现的端点的线性组合。由于空间分布的高相关性,可以假设可以从局部背景字典 A 中提取端点。稀疏表示算法用于找到那些端元并恢复丰度矢量 α 。代替使用所有原子,稀疏表示利用小子集 A 来线性地表示中心测试样本。因此 α 是稀疏向量。为了物理上有意义, α 必须满足非负性和一对一约束。然后 α 可以通过以下优化问题近似恢复:

$$\min_{\alpha} \|y-A\alpha\|_2^2 \quad \text{s.t.} \quad \|\alpha\|_0 \leq K_0, \alpha \geq 0 \text{ and } 1\alpha=1 \quad (5)$$

式中: $\|\cdot\|_0$ 表示 l_0 -norm, 定义为向量中的非零项的数目, K_0 是稀疏水平的给定上限^[6], 1 是 $1 \times s$ 维单位向量。

显然,如果中心测试像素是一个背景像素,可以通过从它的邻居提取的终端来解混。然而,如果中心测试像素是异常像素,由于其局部背景字典中的异常末端的缺失,解混合过程将导致大的残差。

通过放宽被最小化的总和约束 $(1\alpha-1)^2$, 稀疏重建问题(5)被修改为:

$$\min_{\alpha} \|y-A\alpha\|_2^2 + \lambda^2(1\alpha-1)^2 \quad \text{s.t.} \quad \|\alpha\|_0 \leq K_0 \text{ and } \alpha \geq 0 \quad (6)$$

式中: λ^2 为拉格朗日因子。

目标函数可被简化为:

$$\begin{aligned} \|y-A\alpha\|_2^2 + \lambda^2(1\alpha-1)^2 &= (y-A\alpha)^T(y-A\alpha) + \\ \lambda^2(1\alpha-1)^T(1\alpha-1) &= (y^T y + \lambda^2) + \alpha^T(A^T A + \lambda^2 1^T 1)\alpha - \\ 2(y^T A + \lambda^2 1)\alpha &= \|\tilde{y} - \tilde{A}\alpha\|_2^2 \end{aligned} \quad (7)$$

式中: $\tilde{A}=[A; \lambda 1], \tilde{y}=[y; \lambda]$ 。

因此,优化问题(6)可以被替换为:

$$\min_{\alpha} \|\tilde{y} - \tilde{A}\alpha\|_2^2 \quad \text{s.t.} \quad \|\alpha\|_0 \leq K_0 \text{ and } \alpha \geq 0 \quad (8)$$

它是一个具有非负性约束的线性系统。该系统的非负稀疏解可以通过 NOMP 算法大致恢复。与参考文献[6]中目标检测的 SR 类似,当达到某个稀疏水平(控制迭代次数)时,NOMP 算法终止,因为检测器完全基于重建误差。

实验上,在均匀区域中,发现所选择的原子 α 和系数在具有或不具有和至约束的情况下是相似的,从而导致类似的残差。然而,在异质区域中,没有约束的 NOMP 倾向于对一些正常背景像素使用大系数来表示中心异常像素,使得残差更小。因此,和一约束可以提高检测器的判别力。

2.2 NOMP 的预处理

在解决优化问题(8)之前,笔者采取有效的预处理以改善 NOMP 的行为。在参考文献[13]中证明,该预处理不改变原始线性系统的解决方案,并且在表示中表现更好。

首先,重新缩放矩阵 \tilde{A} 以具有系数的单位列和:

$$D=\tilde{A}W^{-1}, \beta=W\alpha \quad (9)$$

式中: W 是具有条目的对角矩阵 $W_{ij}=\sum_i \tilde{A}_{ij}$ 。显然, \tilde{A} 中没有零列,因此 W 是可逆的。所以笔者可以得到规范化的系统 $\tilde{y}=D\beta$ 以及 $\sum_j D_{ij}=1$ 。

第二,集中线性系统 $\tilde{y}=D\beta$:

$$B=PD, z=P\tilde{y} \quad (10)$$

其中中心矩阵 $P=I-\frac{1-\tau}{n}1_{n \times n}, 1_{n \times n}$ 是 $n \times n$ 维单位矩阵, τ 是一个小的正常数满足 $0 < \tau < 1$ 。

然后得到一个具有相同解决方案的新系统:

$$\min_{\beta} \|z-B\beta\|_2^2 \quad \text{s.t.} \quad \|\beta\|_0 \leq K_0 \text{ and } \beta \geq 0 \quad (11)$$

在稀疏向量 $\hat{\beta}$ 恢复之后, 异常可以通过被定义为集中测试样本与其近似之间的重建误差的残差来确定。因此, 提出的 NSR-STO 的输出是:

$$r = \|z - B\hat{\beta}\|_2 \quad (12)$$

如果残差大于给定阈值, 则 y 被标记为异常像素。

2.3 原始背景字典的删减

在所提出的算法中, 假设局部背景字典的所有原子与中心异常像素完全不同。然而, 在异常像素出现在块中的情况下, 中心异常像素的小连续区域都是异常的, 而不管内部保护窗口。即使是与中心异常像素相似的一个相邻像素也应该产生假阴性。为了解决这个问题, 的目标是修剪类似于原始背景字典中提出的中心样本的原子。

对于 \tilde{A} 中的每个 \tilde{a}_i , 采用以下线性表示误差来描述 \tilde{y} 与 \tilde{a}_i 之间的相似性:

$$\begin{aligned} \varepsilon(i) &= \min_{\alpha_i \geq 0} \|\tilde{y} - \tilde{a}_i \alpha_i\|_2^2 = \min_{\alpha_i \geq 0} (\tilde{y} - \tilde{a}_i \alpha_i)^T (\tilde{y} - \tilde{a}_i \alpha_i) = \\ &= \min_{\alpha_i \geq 0} \tilde{y}^T \tilde{y} + (\tilde{a}_i^T \tilde{a}_i)^T \alpha_i^2 - \frac{(\tilde{a}_i^T \tilde{y})^2}{\tilde{a}_i^T \tilde{a}_i} = \\ &= \tilde{y}^T \tilde{y} - \frac{\max\{\tilde{a}_i^T \tilde{y}, 0\}^2}{\tilde{a}_i^T \tilde{a}_i} \end{aligned} \quad (13)$$

式中: α_i 是 \tilde{a}_i 线性表示系数。

约束 $\alpha_i \geq 0$ 被特别设计以使修剪的原子与测试样本呈正相关。然后对错误进行排序, 并删除具有小误差的原子。经验上, 10% 足够大以排除 HSI 中大多数情况下的异常像素, 并且它还可以保留足够的背景像素。因此在以下实验中使用 10%。

在所提出的算法(表示 NSR-STO)与其他算法之间存在紧密相关性。对于非常小的 K_0 , NSR-STO 被简并为简单的模板匹配, 其通常是欠拟合的, 导致检测性能的削弱。另一方面, 当 K_0 足够大到是 A 原子的数量时, 所有原子将被用于协作地表示测试样本, 因此稀疏表示被减少为协作表示。在这种情况下, NSR-STO 算法等同于 CR 算法。

提出的 HSI 的 NSR-STO 算法的实现细节如表 1 所示。

表 1 用于 HSI 的 NSR-STO 算法

Tab.1 Proposed NSR-STO algorithm for HSI

Input: A 3-D hyperspectral cube, window size (W_{in}, W_{out}) , and parameters λ, K_0

Initialization: Linearly normalize the HSI

For each test pixel y in the hyperspectral scene:

- 1) Collect the local background dictionary A
- 2) Construct matrix \tilde{A} and vector \tilde{y}
- 3) Prune dictionary \tilde{A} based on the errors in (13)
- 4) Normalize \tilde{A} and α via (9) to get the system $\tilde{y} = D\beta$
- 5) Center D and \tilde{y} via (10) to get the system $z = B\beta$
- 6) Solve the system (11) by the NOMP algorithm
- 7) Compute the residual via (12)

End For

Output: A 2-D anomaly detection map

3 试验结果

高光谱数据集由机载可见/红外成像光谱仪 (AVIRIS) 获得。具有覆盖来自加利福尼亚州圣地亚哥的海军航空站的具有像素大小 的图像数据集具有范围从 370~2 510 nm 的 224 个光谱带。在去除吸水带和低 SNR 带之后保留了总共 189 个带 (1~6, 33~35, 97, 107~113, 153~166 和 221~224)。实验中, 选择具有像素大小 的两个感兴趣区域(命名为 ROI-I 和 ROI-II)。场景和异常的地面真实信息如图 2 所示。




图 2 场景和异常的地面真实图

Fig.2 Image scene and the ground-truth map

3.1 参数优化

在此节中,检查参数 λ 的影响和 K_0 使用两个 ROI。通过接收器操作特性(ROC)曲线和 ROC 曲线下面积(AUC)比较检测性能。对于 ROI-I 和 ROI-II,窗口大小(w_{in}, w_{out})分别被优选地选择为(7, 11)和(11, 17)NSR-STO 具有不同 λ 和 K_0 AUC 结果显示在表 2 中。

表 2 不同 AND 值,NSR-STO 的 AUC 结果

Tab.2 AUC values of NSR-STO with different values of AND

AUC values	$\lambda=0$	$\lambda=0.5$	$\lambda=1$	$\lambda=1.5$	$\lambda=2$	
ROI-I	$K_0=2$	0.964 0	0.980 3	0.983 1	0.983 1	0.983 1
	$K_0=4$	0.970 2	0.983 3	0.986 0	0.986 0	0.986 0
	$K_0=6$	0.973 0	0.983 8	0.986 4	0.986 4	0.986 4
	$K_0=8$	0.973 8	0.983 8	0.986 4	0.986 4	0.986 4
ROI-II	$K_0=2$	0.984 1	0.994 9	0.997 3	0.997 3	0.997 3
	$K_0=4$	0.987 8	0.995 4	0.997 4	0.997 4	0.997 4
	$K_0=6$	0.988 7	0.995 4	0.997 4	0.997 4	0.997 4
	$K_0=8$	0.988 8	0.995 4	0.997 4	0.997 4	0.997 4

对于非常小的 λ ,一对一约束被削弱,通常导致较差的性能。通常,对于某些稀疏水平,AUC 性能随着增加而提高。当 λ 增加到某一水平(即 $\lambda=1$)时, α 总和接近 1,变化的冗余增量对系数 α 的影响很小,因此 $\lambda \geq 1$ 时 AUC 值不增加。通过比较不同 λ 值的 AUC 表现,可以发现 ROI-I 和 ROI-II 的最佳值为 1。

类似地,对于特定 λ ,AUC 性能随着 K_0 增加而提高。然而,当 K_0 增加到某一水平(即对于 ROI-I $K_0 \geq 6$ 和对于 ROI-II $K_0 \geq 4$)时,AUC 值不增加。实验上,对于大的 K_0 ,发现一些 α 系数是 0。它表示 \tilde{A} 中仅有个别元素被利用。因此,冗余增量 K_0 不会增加 AUC 值。同时,作为 NOMP 算法的迭代的稀疏级别 K_0 也是控制 NSR-STO 的执行时间的重要因素。实验上,发现执行时间近似线性增加, K_0 增大时。因此,大量 K_0 不是必需的。给定计算复杂度,对于两个 ROI,选择最佳 K_0 值为 6。

3.2 检测性能评价

在此节中,通过与 RX^[1],SVDD^[3],CR^[8]和 SR(没有非负性和一对一约束)进行比较来评估所提出的 NSR-STO 的检测性能。参数 λ 和 K_0 被设置为上述

最佳值。手动调整上述算法的所有参数以获得最佳性能。在具有与前述相同的窗口尺寸的情况下,用于上述检测器的 ROC 曲线在图 3 中示出。可以看出,在 ROI-I 的低误报率区域中,只有 SVDD 的性能优于 NSR-STO。然而,在高假警率区域,NSR-STO 优于所有其他检测器。一般来说,提出的 NSR-STO 提供比其他检测器更好的结果。上述检测器的 AUC 值示于表 III 中。再次,建议的 NSR-STO 执行最好的。通过比较 NSR-STO 和 SR,我们可以得出结论,通过施加非负性和一对一约束,检测性能得到很大改善。

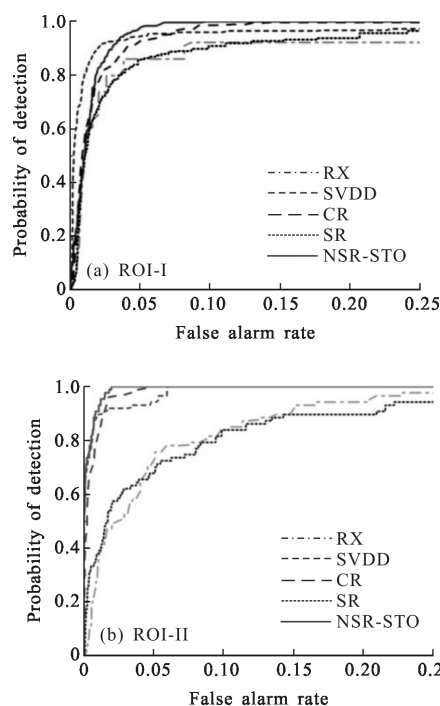


图 3 在两个 ROI 区中 RX,SVDD,CR,SR 与 NSR-STO 的比较
Fig.3 ROC comparison for RX, SVDD, CR, SR, and NSR-STO with the two ROIs

还比较了上述检测器的计算复杂性。实验在具有 2 GB RAM 的 2.93 GHz Intel Core 2 Duo CPU 上的 MATLAB 中进行。上述检测器的执行时间如表 3 所示。所提出的 NSR-STO 主要通过由 Matlab 的 lsqnonneg 指令解决的 NOMP 中的非负最小二乘问题来计算。SVDD 算法具有最大的执行时间,这是由于二次规划的巨大的计算复杂性,它由 Matlab 的 quadprog 指令解决。可以看出,与其他检测器相比,NSR-STO 具有相对较低的计算复杂性,特别是对于大的。

表 3 两个 ROIS 的 AUC 值及执行时间 (s)

Tab.3 AUC values/ execution times with the two ROIS(s)

	AD	RX	SVDD	CR	SR	NSR-STO
ROI-I	AUC	0.965 7	0.975 4	0.982 8	0.959 2	0.986 4
	Times	41.88	153.32	14.47	10.35	38.72
ROI-II	AUC	0.952 0	0.994 4	0.994 7	0.937 7	0.997 4
	Times	59.60	651.68	63.72	16.99	55.64

4 结 论

该文中,提出了一种新的非负稀疏表示检测器用于高光谱子像素异常检测。非负性和一对一约束强加了物理意义和更好的检测性能。此外,引入包括归一化和集中化的有效预处理以改善 NOMP 的行为。为了排除原始背景字典中的潜在异常像素,我们修剪类似于中心样本的原子。对实际数据集的实验证明,所提出的 NSR-STO 在检测性能和计算复杂性方面优于其他算法。

参考文献:

[1] Reed I S, Yu X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution [J]. *IEEE Trans Acoust Speech Signal Process*, 1990, 38(10): 1760-1770.

[2] Kwon H, Nasrabadi N M. Kernel RX-algorithm: A nonlinear anomaly detector for hyperspectral imagery [J]. *IEEE Trans Geosci Remote Sens*, 2010, 48(11): 4099-4109.

[3] Bannerjee A, Burlina P, Diehl C. A support vector method for anomaly detection in hyperspectral imagery [J]. *IEEE*

Trans Geosci Remote Sens, 2006, 44(8): 2282-2291.

[4] Gurram P, Kwon H. Support-vector-based hyperspectral anomaly detection using optimized kernel parameters [J]. *IEEE Geosci Remote Sens Lett*, 2011, 8(6): 1060-1064.

[5] 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.

[6] Zhang Y, Du B, Zhang L. A sparse representation-based binary hypothesis model for target detection in hyperspectral images [J]. *IEEE Trans Geosci Remote Sens*, 2015, 53(3): 1346-1354.

[7] Chen Y, Nasrabadi N M, Tran T D. Simultaneous joint sparsity model for target detection in hyperspectral imagery [J]. *IEEE Geosci Remote Sens Lett*, 2011, 8(4): 676-680.

[8] Li W, Du Q. Collaborative representation for hyperspectral anomaly detection [J]. *IEEE Trans Geosci Remote Sens*, 2015, 53(3): 1463-1474.

[9] Yuan Z, Sun H, Ji K, Li Z, Zou H. Local sparsity divergence for hyperspectral anomaly detection [J]. *IEEE Geosci Remote Sens Lett*, 2014, 11(10): 1697-1701.

[10] Li J, Zhang H, Zhang L, Ma L. Hyperspectral anomaly detection by the use of background joint sparse representation [J]. *IEEE J Sel Topics Appl Earth Observ Remote Sens*, 2015, 8(6): 2523-2533.

[11] Zhang L, Yang M, Feng X. Sparse representation or collaborative representation: Which helps face recognition[C] //IEEE Int Conf Comput Vis Barcelona, Spain, 2011: 471-478.

[12] Liu J Zhang J. Spectral unmixing via compressive sensing[J]. *IEEE Trans Geosci Remote Sens*, 2014, 52(11): 7099-7110.

[13] Bruckstein A M, Elad M, Zibulevsky M. On the uniqueness of nonnegative sparse solutions to underdetermined systems of equations [J]. *IEEE Trans Inf Theory*, 2008, 54(11): 4813-4820.