

基于增量学习的高光谱图像目标检测

张宁¹, 陈嘉杰², 伍伟¹, 沈霁¹, 袁杰¹, 朱新忠¹, 谢凤英²

(1. 上海航天电子技术研究所, 上海 201109; 2. 北京航空航天大学 宇航学院, 北京 100191)

摘要: 高光谱图像目标检测是高光谱图像分析中的重要研究内容之一。本文从经典有效的约束能量最小化算法出发, 提出了一种基于增量学习的高光谱目标检测方法。当获得新的样本时, 不需要重新计算所有样本的自相关矩阵即可对检测器模型进行更新, 减轻了星上有限计算资源的负担。实验结果表明: 本文提出的目标检测算法在压制背景光谱的同时可以更好地适应目标光谱, 提高了算法的检测性能。

关键词: 高光谱图像; 目标检测; 增量学习; 约束能量最小化; 背景压制

中图分类号: TP 181

文献标志码: A

DOI: 10.19328/j.cnki.1006-1630.2019.05.006

Hyperspectral Target Detection Algorithm Based on Incremental Learning

ZHANG Ning¹, CHEN Jiajie², WU Wei¹, SHEN Ji¹,

YUAN Jie¹, ZHU Xinzong¹, XIE Fengying²

(1. Shanghai Aerospace Electronic Technology Institute, Shanghai 201109, China;

2. School of Astronautics, Beihang University, Beijing 100191, China)

Abstract: Hyperspectral image target detection is one of the most important research directions in hyperspectral image analysis field. In this paper, an incremental learning based target detection method is proposed. We design the incremental form of the classical constrained energy minimization algorithm. When a new sample is obtained, the proposed method will update the model without recalculating the auto-correlation matrix of all samples, which reduces the burden of on-board calculations. Experiments show that the proposed method can adapt the target spectrum while suppressing the background spectrum, which improves the detection accuracy effectively.

Keywords: hyperspectral image; target detection; incremental learning; constrained energy minimization; background suppression

0 引言

高光谱图像在获得物体空间信息的同时, 也包含了丰富的光谱信息, 其每个位置的像素都包含一条近似连续的光谱曲线^[1]。相比于普通遥感图像, 高光谱图像的空间分辨率较低, 但光谱分辨率很高, 因此可以利用物体的光谱特性进行区分。高光谱图像的目标检测可以应用于很多领域, 包括军事侦查、资源探测、植被分析等^[2]。

高光谱图像目标检测按照目标光谱是否可知可分为目标检测和异常检测。基于先验光谱信息的目标检测本质上可视为一个二元分类器(目标-背景)。

常见的高光谱目标检测算法包括光谱角度匹配法^[3-4](spectral angle mapping, SAM)、自适应一致估计法^[5-6](adaptive coherence estimator, ACE)、正交子空间投影法^[7](orthogonal subspace projection, OSP)、约束能量最小化算法^[8-10](CEM)稀疏表达法^[11-12]和基于变分的检测方法等^[13]。其中CEM利用特定的约束条件设计一个有限脉冲响应滤波器(FIR), 增强目标光谱, 抑制背景光谱。与其他目标检测方法相比, CEM只需要知道目标的光谱先验而不需要背景光谱先验, 应用范围更加广泛, 且在消除未知信号及抑制噪声方面有显著优势^[14]。

然而真实环境中捕获的高光谱数据通常会受到环境因素的影响(如大气散射、湍流、光照条件、成像噪声等),与已知的光谱先验不完全一致^[15-16],此时只用光谱库中的光谱作为先验很难得到较好的检测效果。

针对光谱先验与实际环境中的目标光谱不一致的情况,本文在 CEM 检测的基础上提取相应的目标与背景光谱,并通过增量学习的形式更新检测器。该算法不需要重新计算所有样本的自相关矩阵,能够以很小的计算资源提高检测精度,在星上在轨目标检测领域有重要的应用价值。

1 约束能量最小化检测算法原理

CEM 的目标是从能量的角度压制背景从而提取目标。为此,HARSANYI 设计了一个有限脉冲响应滤波器^[8],通过添加目标光谱先验的输出为定值的约束,CEM 能抑制背景信息而使目标像素保持较大的输出,从而有效地分离目标光谱与背景光谱。

设高光谱图像中所有像元构成的样本集为 $X = \{x_1, x_2, \dots, x_N\}$, 其中 $x_i = (x_{i1}, x_{i2}, \dots, x_{iL})^T$ 为第 i 个样本, N 为像元的数目, L 为每一像元的波段数, $d = (d_1, d_2, \dots, d_L)^T$ 是已知的目标光谱先验, CEM 的目的就是设计一个有限脉冲响应滤波器 $w = (w_1, w_2, \dots, w_L)^T$, 使经过该滤波器后,目标光谱仍能保持一定大小的输出,而背景光谱得到抑制,因此滤波器应该满足如下约束:

$$d^T w = \sum_{l=1}^L d_l w_l = 1 \quad (1)$$

对于高光谱图像,其经过滤波器后的平均输出“能量”可用每个像素的输出值的平方和来表示,具体可写为

$$E\{y^2\} = E\{(w^T x)^2\} = w^T R w \quad (2)$$

式中: y 为检测的输出; w 为滤波器的系数; $R = \frac{1}{N} \left(\sum_{i=1}^N x_i x_i^T \right)$ 是样本集合 S 的样本自相关矩阵。对滤波器的设计其实就是对系数 w 的优化过程,其可以归结为最小值问题,即

$$\begin{cases} \min w^T R w \\ d^T w = 1 \end{cases} \quad (3)$$

对于式(3)所示的条件极值问题,可以运用拉格朗日乘子法对上述问题进行求解,得

$$w^{\text{CEM}} = \frac{R^{-1} d}{d^T R^{-1} d} \quad (4)$$

式中: w^{CEM} 代表了最佳的滤波器系数。这个系数在保持已知目标输出不变的情况下有效地抑制了背景,使重要的目标信号能够被提取。对于任意输入向量 x_i , CEM 滤波器的输出响应 y_i 为

$$y_i = w_{\text{CEM}}^T x_i = \left(\frac{R^{-1} d}{d^T R^{-1} d} \right)^T x_i = \frac{d^T R^{-1} x_i}{d^T R^{-1} d} \quad (5)$$

2 基于增量学习的约束能量最小化检测

约束能量最小化算法的核心思想是使背景光谱的平均输出能量最小,通过优化,目标与背景的输出得到了一定程度的区分。然而,单层的 CEM 检测器的检测精度是有限的。

针对上述现象,本文从增量学习的角度出发,将多层 CEM 进行级联,保留每一层迭代中对滤波器响应较大的光谱向量,同时抑制响应较小的光谱向量,以增加光谱和背景的区分度,并利用 Sherman-Morrison 定理,省略了后续级联层中自相关矩阵的计算,在简化计算复杂度的同时提升了 CEM 的检测精度。其理论推导如下:

设 R_k 和 R_{k-1} 为相邻两次迭代的自相关矩阵,则有

$$R_k - R_{k-1} = \frac{1}{N} \left(\sum_{i=1}^N (I(y_i^{k-1})^2 x_i^{k-1} x_i^{k-1T} - x_i^{k-1} x_i^{k-1T}) \right) \quad (6)$$

其中,

$$I(t) = \begin{cases} 1 - e^{-\lambda t}, & t \geq 0 \\ 0, & t < 0 \end{cases}$$

因此, $I(y_i^{k-1})$ 为一个 $0 \sim 1$ 之间的数,它代表了该光谱与目标光谱间的相似程度, y 值越大,则越有可能是目标光谱,对于 y 值小于 0 的光谱,经过非线性抑制后其在下一次的自相关矩阵中的影响已被完全消去。根据每一次迭代后的输出值可以筛选出相应的目标光谱 d_m 与背景光谱 u_m , 两者表达式如下:

$$d_m = x_i, \text{ if } y_i = \max(y) \quad (7)$$

$$u_m = \frac{1}{\alpha} \left(\sum_{i=1}^{\alpha} x_i \right), \text{ if } I(y_i) = 0 \quad (8)$$

式中: α 为满足条件的光谱个数。

用背景光谱的平均值近似表示被抑制至 0 的背景光谱,同时忽略那些未被抑制或抑制不明显的光

谱,则式(6)可以简化为

$$R_k - R_{k-1} = -\frac{\alpha}{N} u_m u_m^T \quad (9)$$

Sherman 和 Morrison 等提出了通过矩阵分解求解逆矩阵的一种方法^[17]。基于 Sherman-Morrison定理,下一次迭代的自相关矩阵的逆矩阵可以表示为

$$R_k^{-1} = \left(R_{k-1} - \frac{\alpha}{N} u_m u_m^T \right)^{-1} = R_{k-1}^{-1} - \frac{R_{k-1}^{-1} \left(-\frac{\alpha}{N} u_m \right) u_m^T R_{k-1}^{-1}}{1 + u_m^T R_{k-1}^{-1} \left(-\frac{\alpha}{N} u_m \right)} \quad (10)$$

而新的目标光谱 d_k 可表示为

$$d_k = \frac{(k-1)d_{k-1} + d_m}{k} \quad (11)$$

式中: k 为迭代次数。

利用式(10)与式(11),就可以在不重新计算样本自相关矩阵的前提下完成对检测器的更新,将更新后的 R_{k+1}^{-1} 与 d_{k+1} 代入式(4),可以得到 $k+1$ 次迭代的滤波器系数。循环终止的条件为两次迭代的输出 y 收敛,即两次输出能量间的差值小于阈值 ϵ ,即

$$E\{(y^k)^2\} - E\{(y^{k-1})^2\} < \epsilon \quad (12)$$

基于增量学习的约束能量最小化算法流程如图 1 所示。

3 实验结果及分析

实验环境统一为 CPU 频率为 1.1 GHz 的 PC 机,算法运行在 Matlab 2016b 上。实验中的超参数都统一设置为 $\lambda = 200$, $\epsilon = 10^{-5}$ 。本文方法将与 CEM^[10]、SAM^[5]、ACE^[7] 这 3 种方法进行对比,从仿真图像、真实图像、算法时间复杂度这 3 个方面来验证其有效性。

3.1 仿真高光谱图像实验

本实验所用的仿真高光谱图像是通过美国地质调查局(USGS)数字光谱库得到的。USGS 光谱数据共包含 224 个波段,光谱范围是 $0.4 \sim 2.5 \mu\text{m}$ 。该图像中包含 15 种物质的光谱,两个目标。实验加入了信噪比为 30 dB 的高斯白噪声以检测算法的鲁棒性。图 2(a)显示了该高光谱仿真图像的第一波段,图 2(b)则为其中目标的真实分布,图 2(c)~图 2(f)分别为 CEM、SAM、ACE 和本文提出的算法,为了便于比较,4 种算法的输出都被归一化到 $0 \sim 1$




图 1 基于增量学习的约束能量最小化算法流程

Fig.1 Flow chart of CEM based on incremental learning

之间。可以看到 CEM 和 SAM 算法检测失败,ACE 算法仍然有很多的虚假目标被检测,而本文方法最大程度地抑制了背景光谱,降低了虚警率,具有更好的检测效果。

ROC 曲线描述了目标检测中虚警率与检测率之间的变化关系,当虚警率相同时,算法的检测率越高则性能越好。图 3 给出了 4 种算法的 ROC 曲线,可以看到本文的 ROC 曲线更加靠近左上角,ROC 曲线下的面积最大,因此本文的算法检测性能最好。

3.2 真实高光谱图像实验

真实高光谱图像采用美国圣地亚哥机场的 AVIRIS 图像,该图像是采用机载可视/红外成像光谱仪拍摄,共有 224 个波段,波段范围是 $0.4 \sim$




图 2 不同算法在仿真高光谱图像上的检测结果

Fig.2 Detection results of various algorithms on simulated hyperspectral images




图 3 在仿真图像上的 ROC 曲线

Fig.3 ROC curves of various algorithms on simulated hyperspectral images

2.5 μm , 图像中包含了 3 个飞机目标。实验中实际使用其中的 189 个高信噪比的波段。图 4 显示了对真实图像的检测结果, 其中, 图 4(a) 为图像的第一波段, 图 4(b) 为其中目标的真实分布, 图 4(c)~图 4(f) 分别为 CEM、SAM、ACE 和本文提出的算法, 结果同样被归一化到 0~1 区间。可以看到 SAM 算法检测失败。CEM 虽然在目标处有比较强的响应, 但背景光谱抑制得不干净, 有许多背景噪声。ACE 算法过度抑制了噪声光谱从而出现目标丢失

现象, 而本文方法能够很好地抑制背景并成功检测出目标。

图 5 为 4 种算法在该真实图像上的 ROC 曲线。可以看出, 本文算法的曲线拥有最大的曲线下面积, 检测效果最好。

3.3 时间复杂度

运行时间是衡量算法性能的重要方面, 尤其在星上处理时, 对算法时间的要求更加迫切。表 1 显示了 4 种算法在仿真图像与真实图像上的运行时间。由于本文方法是采用 CEM 算法进行目标初始检测, 在此基础上通过增量学习得到最终检测结果, 因此本文方法的运算时间可分解为初始检测时间 (CEM 算法的时间) 和增量学习过程所用的迭代时间。可以看出, 本算法作为 CEM 算法的增量学习版本, 在以 CEM 算法作为初始迭代的情况下, 仿真图像上的耗时仅比 CEM 算法高出 0.015 s, 实际图像上的耗时比 CEM 高出 0.047 s, 同时总用时远低于其他两种算法。这说明后续几次增量迭代所需的时间消耗是很低的。增量迭代用矩阵相乘代替自相关矩阵的求逆, 矩阵求逆的复杂度为 $O(L^3)$, 而矩阵乘法的复杂度为 $O(L^2)$ 。因此, 本文算法的复杂




图 4 不同算法在真实图像上的检测结果
Fig.4 Detection results of various algorithms on real hyperspectral images




图 5 在真实图像上的 ROC 曲线
Fig.5 ROC curves of various algorithms
on real hyperspectral images

度得到了数量级的减弱,有效减少了计算资源的消耗。

表 1 不同算法的运行时间

Tab.1 Run time of different algorithms					s
参数	CEM	SAM	ACE	ICEM(CEM 初始检测+增量学习)	
仿真图像	0.054	0.092	0.340	0.054+0.015(迭代 4 次)	
真实图像	0.202	0.576	1.434	0.202+0.057(迭代 4 次)	

4 结 论

本文提出了一种基于增量学习的约束能量最小化算法,利用 Sherman-Morrison 定理,不需要重新计算自相关矩阵的逆矩阵即可更新滤波器权重,有效减少了算法的计算复杂度。此外,通过仿真高光谱图像与真实高光谱图像的实验,算法的检测精度较传统高光谱目标检测算法有明显提升。因此本文算法在精度与速度层面都取得了满意的效果,有望在星上计算资源有限的条件下得到实际应用。

参考文献

[1] GREEN R O, EASTWOOD M L, SARTURE C M, et al. Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (AVIRIS)[J]. Remote Sensing of Environment, 1998, 65(3): 227-248.

[2] 张宁, 赵睿, 白郁, 等. 基于集成学习约束能量最小化的高光谱目标检测算法研究[J]. 上海航天, 2018, 35(1): 23-29.

[3] HAO Z, BIN W, ZHANG L M. A new scheme for detection and classification of subpixel spectral signatures in multispectral data[C]//International Symposium on Advances in Neural Networks-ISNNDBLP.

- 2004; 331-336.
- [4] KRUSE F A, LEFKOFF A B, BOARDMAN J W, et al. The spectral image processing system (SIPS)-interactive visualization and analysis of imaging spectrometer data[J]. *Remote Sensing of Environment*, 1993, 44(2/3): 145-163.
- [5] CHANG C I. An information-theoretic approach to spectral variability, similarity, and discrimination for hyperspectral image analysis[J]. *IEEE Transactions on Information Theory*, 2000, 46(5): 1927-1932.
- [6] SOBRINO J A, JIMENEZ-MUNOZ J C, ZARCO-TEJADA P J, et al. Land surface temperature derived from airborne hyperspectral scanner thermal infrared data[J]. *Remote Sensing of Environment*, 2006, 102(1/2): 99-115.
- [7] MANOLAKIS D, LOCKWOOD R, COOLEY T, et al. Is there a best hyperspectral detection algorithm [C]//*Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XV*. International Society for Optics and Photonics, 2009, 7334: 733402.
- [8] HARSANYI J C, CHANG C I. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1994, 32(4): 779-785.
- [9] ZOU Z, SHI Z, WU J, et al. Quadratic constrained energy minimization for hyperspectral target detection [C]//*IGARSS*. 2015: 4979-4982.
- [10] ZOU Z, SHI Z. Hierarchical suppression method for hyperspectral target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(1): 330-342.
- [11] ZHANG Y, KE W, DU B, et al. Independent encoding joint sparse representation and multitask learning for hyperspectral target detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(11): 1933-1937.
- [12] ZHU D, DU B, ZHANG L. Target dictionary construction-based sparse representation hyperspectral target detection methods[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(4): 1254-1264.
- [13] YANG S, SHI Z. Hyperspectral image target detection improvement based on total variation[J]. *IEEE Transactions on Image Processing*, 2016, 25(5): 2249-2258.
- [14] QIAN D, HSUANR. Performance analysis for CEM and OSP [J]. *The International Society for Optical Engineering*, 2002, 4725: 501-508.
- [15] MANOLAKIS D, MARDEN D, SHAW G A. Hyperspectral image processing for automatic target detection applications[J]. *Lincoln Laboratory Journal*, 2003, 14(1): 79-116.
- [16] WANG T, DU B, ZHANG L. An automatic robust iteratively reweighted unstructured detector for hyperspectral imagery [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2367-2382.
- [17] SHERMAN J, MORRISON W J. Adjustment of an inverse matrix corresponding to a change in one element of a given matrix[J]. *The Annals of Mathematical Statistics*, 1950, 21(1): 124-127.

(本文编辑:姚麒伟)