

引用格式:杨瑞峰,黄山.基于正则化参数自适应估计的运动目标提取[J].电光与控制,2018,25(11):79-83,88. YANG R F, HUANG S. Moving target extraction based on adaptive estimation of regularized parameter[J]. Electronics Optics & Control, 2018, 25(11):79-83, 88.

## 基于正则化参数自适应估计的运动目标提取

杨瑞峰, 黄山

(四川大学电气信息学院,成都 610065)

**摘要:**针对在基于迭代张量高阶奇异值分解(HOSVD)实现运动目标提取过程中面临的正则化参数的手动选择问题,采用 Morozov's 偏差准则的方法实现基于 HOSVD 的运动目标检测的正则化参数自适应估计。正则化参数根据误差水平进行选择和调整,在算法迭代中实现收敛。实验证明,所提方法减少了调试时间,并且能较准确完整地提取运动目标。

**关键词:**运动目标提取;目标检测;Morozov's 偏差准则;正则化参数;自适应估计

**中图分类号:** TP391 **文献标志码:** A **doi:**10.3969/j.issn.1671-637X.2018.11.015

## Moving Target Extraction Based on Adaptive Estimation of Regularized Parameter

YANG Rui-feng, HUANG Shan

(College of Electrical Engineering & Information, Sichuan University, Chengdu 610065, China)

**Abstract:** To solve the problem of manual selection of regularized parameters in the process of moving target extraction based on iterative tensor High-Order Singular Value Decomposition (HOSVD), Morozov's deviation criterion is used to achieve the adaptive estimation of normalized parameters in moving target detection based on HOSVD. The regularized parameter is selected and adjusted according to the error level, and rapid convergence is realized in the iterative process of the algorithm. Experiments prove that this method greatly reduces the debugging time, and can accurately and completely extract the moving targets.

**Key words:** moving target extraction; target detection; Morozov's discrepancy principle; regularized parameter; adaptive estimation

### 0 引言

图像作为人类感知世界的视觉基础,是人类获取信息、表达信息和传递信息的重要手段。随着计算机视觉和图像处理在各个领域内的广泛应用,运动目标检测<sup>[1]</sup>成为当今研究的热点。近些年来,基于稀疏表示的压缩感知理论发展使稀疏表示成为一种有效的数据表示方式。低秩矩阵恢复(RPCA)<sup>[1]</sup>已经成为一种流行的数据获取和表示方式,随着文献[2]提出矩阵RPCA,开始通过引入稀疏表示从而提高对含有大噪声和异常点的观测数据的鲁棒性。然而随着现代视频数据的数据结构维度增高和更为复杂,为了更好地表达高阶数据复杂的本质结构,文献[3]提出张量高阶奇异值分解,将矩阵的奇异值分解扩展到张量,为高维

数据的分析和处理提供有力的支撑。因此,越来越多的研究人员运用张量高阶奇异值分解来实现运动目标提取。但是对实验正则化参数的调试过程是一项工作量大并且耗时长工程,研究者们开始关注于正则化参数的自适应估计。现有选择参数的方法有 Morozov's 偏差准则<sup>[4]</sup>、广义交叉验证法(Generalized Cross-Validation, GCV)<sup>[5]</sup>、Curve 法<sup>[6]</sup>和变分贝叶斯法(Variational Bayes' Approach)<sup>[7]</sup>等。文献[8]中利用 Morozov's 偏差准则实现了基于全变分的图像去模糊的正则化参数自适应估计,受此启发,本文将采用 Morozov's 偏差准则实现基于 HOSVD 的运动目标检测的正则化参数自适应估计。

### 1 Morozov's 偏差准则

以图像恢复为例引入 Morozov's 偏差准则。一般而言,图像的退化过程可以表示为

$$V = KU_{\text{clean}} + N \quad (1)$$

式中:  $V$  为观测图像;  $K$  为已知的模糊算子的矩阵表

收稿日期:2017-10-20

修回日期:2017-12-07

作者简介:杨瑞峰(1994—),男,河南信阳人,硕士生,研究方向为数字图像处理。

示形式;  $\mathbf{U}_{\text{clean}}$  为原始图像;  $\mathbf{N}$  为高斯白噪声。根据  $\mathbf{V}$  估计出  $\mathbf{U}_{\text{clean}}$  是一个不适定逆问题。用正则化方法求解该问题的最小化方程, 即

$$\min_{\mathbf{U}} \left\{ J(\mathbf{U}) + \frac{\lambda}{2} \|\mathbf{KU} - \mathbf{V}\|_2^2 \right\} \quad (2)$$

式中:  $J(\mathbf{U})$  为正则项,  $\mathbf{U}$  为  $\mathbf{U}_{\text{clean}}$  的估计值; 二次项被称作数据保真项;  $\lambda$  为正则项参数, 平衡了保真项和正则项的相对权重。

根据偏差准则, 上述问题的解应该存在于集合中

$$\mathbf{S} = \{ \mathbf{U}; \|\mathbf{KU} - \mathbf{V}\|_2^2 \leq c \} \quad (3)$$

式中,  $c = \tau mn \sigma^2$ ,  $\tau$  是一个提前确定的参数,  $mn$  表示图像的大小,  $\sigma^2$  表示噪声方差。当噪声方差  $\sigma^2$  未知时, 文献 [9] 提出可以通过中值估计方法 (Median Absolute Deviation, MAD) 估计出  $\sigma^2$ 。该方法的理论基础是噪声小波系数主要集中在高频子带中, 因此可以通过高频子带系数近似估计噪声系数。另外, 中值操作的原因是避免高频子带中存在极少数的大幅度系数对方差估计 [10] 造成影响。MAD 噪声水平估计方法的数学表示为 [11]

$$\sigma = 1.4826 \text{MAD}(\text{real}(Y_{\text{HH}})) \quad (4)$$

式中:  $\text{MAD}(\cdot)$  表示求中值;  $\text{real}(\cdot)$  表示求实部;  $Y_{\text{HH}}$  表示图像经二维小波分解后得到的最高频子带的系数。

在偏差准则下, 式 (2) 问题等价于有约束的优化问题, 即

$$\min_{\mathbf{U}} J(\mathbf{U}) \quad \text{s. t.} \quad \mathbf{U} \in \mathbf{S} \quad (5)$$

通过拉格朗日定理可以将式 (5) 有约束问题转化为式 (2) 无约束问题。如果  $\mathbf{U}$  是特定的  $\lambda$  下式 (5) 的解, 那么它也是式 (2) 的解, 用  $\mathbf{U}^*(\lambda)$  表示式 (2) 对应的最优解。那么, 作为式 (5) 的最小化, 有:  $\mathbf{U}^*(0) \in \mathbf{S}, \lambda = 0$  或者  $\|\mathbf{KU}^*(\lambda) - \mathbf{V}\|_2^2 = c, \lambda > 0$ 。但是, 在实际应用中,  $\lambda$  一般不等于 0, 所以偏差准则实际上是寻找最优参数  $\lambda^* > 0$ 。总而言之, 通过 Morozov's 偏差准则进行自适应参数估计实际上是使误差的二范数等于上限  $\sqrt{c}$  来寻找最优参数  $\lambda^*$ 。当噪声方差可获取时, Morozov's 偏差准则是一个选取参数很好的方法。

## 2 基于正则化参数自适应估计和 HOSVD 的运动目标提取

### 2.1 张量高阶奇异值分解

张量又称为多阶阵列, 是向量和矩阵的高阶推广。其中, 零维张量为标量, 一维张量为向量, 二维张量为矩阵,  $N$  阶张量表示为  $\mathbf{A} \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$ , 其中元素  $(i_1, i_2, \dots, i_N)$  表示为  $a_{i_1, i_2, \dots, i_N}$ 。张量也能够用矩阵形式表示, 该过程称为张量的  $n$ -模式展开, 是将张量的元素重新排列成矩阵。

张量  $\mathbf{A}$  与矩阵  $\mathbf{U} \in \mathbf{R}^{I_n \times I_n}$  的  $n$ -模式积是一个维度

为  $I_1 \times I_2 \times \dots \times I_{n-1} \times J_n \times I_{n+1} \times \dots \times I_N$  的张量, 用  $\mathbf{A} \times_n \mathbf{U}$  表示, 其元素为

$$(\mathbf{A} \times_n \mathbf{U})_{i_1, i_2, \dots, i_{n-1}, i_{n+1}, \dots, i_N} = \sum_{j_n=1}^{I_n} a_{i_1, i_2, \dots, i_n, j_n} u_{j_n} \quad (6)$$

通常要求核张量  $\mathbf{S}$ , 可通过下式求得

$$\mathbf{S} = \mathbf{A} \times_1 (\mathbf{U}^{(1)})^T \times_2 (\mathbf{U}^{(2)})^T \times \dots \times_N (\mathbf{U}^{(N)})^T \quad (7)$$

式中:  $\mathbf{S} \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$  为奇异值分解后得到的核心张量, 矩阵  $\mathbf{U}^{(n)} \in \mathbf{R}^{I_n \times I_n}$  为将张量  $\mathbf{A}$  的  $n$ -模式展开矩阵  $\mathbf{A}_{(n)}$  进行 SVD 分解得到的左酉矩阵, 符号  $\times_n$  表示张量与矩阵的  $n$ -模式积 [12]。

一般情况下, 可以通过 HOSVD 分解找到一个张量  $\tilde{\mathbf{A}}$  近似表示  $\mathbf{A}$ 。首先求得  $\mathbf{A}$  的核张量  $\mathbf{S}$ , 其次对  $\mathbf{S}$  进行阈值收缩得到  $\tilde{\mathbf{S}}$ , 最后通过反变换重建出  $\tilde{\mathbf{A}}$ 。

### 2.2 基于正则化参数自适应估计和 HOSVD 的运动目标提取

将输入的  $I_3$  帧大小为  $I_1 \times I_2 \times 3$  的 RGB 图像序列均转化为  $I_3$  帧大小为  $I_1 \times I_2$  的灰度图序列, 观测图像序列表示为三阶张量  $\mathbf{O} \in \mathbf{R}^{I_1 \times I_2 \times I_3}$ 。恢复张量表示的背景部分可由如下凸优化问题形式表示, 即

$$\min_{\mathbf{B}, \mathbf{M}} \{ \|\mathbf{B}\|_{\text{HOSVD}} + \lambda \|\mathbf{M}\|_1 \} \quad \text{s. t.} \quad \mathbf{O} = \mathbf{B} + \mathbf{M} \quad (8)$$

式中:  $\mathbf{O} \in \mathbf{R}^{I_1 \times I_2 \times I_3}$  为观测图像序列;  $\mathbf{B} \in \mathbf{R}^{I_1 \times I_2 \times I_3}$  为背景部分;  $\mathbf{M} \in \mathbf{R}^{I_1 \times I_2 \times I_3}$  表示前景运动目标部分, 是 3 个大小相同的张量;  $\lambda$  为张量  $\mathbf{O}$  中运动目标部分  $\mathbf{M}$  所占权重系数,  $\|\cdot\|_{\text{HOSVD}}$  表示核张量所有元素之和,  $\|\mathbf{M}\|_1 = \sum_{i_1=1}^{I_1} \sum_{i_2=1}^{I_2} \sum_{i_3=1}^{I_3} |e_{i_1, i_2, i_3}|$ 。

这里, 用  $\frac{1}{\lambda}$  替代之前的  $\lambda$ , 表示正则化参数。将上式转化为无约束的目标方程式为

$$\min_{\mathbf{B}, \mathbf{M}} \left\{ \|\mathbf{B}\|_{\text{HOSVD}} + \frac{1}{\lambda} \|\mathbf{M}\|_1 + \frac{\mu}{2} \|\mathbf{O} - \mathbf{B} - \mathbf{M}\|_2^2 \right\} \quad (9)$$

式中,  $\lambda$  和  $\mu$  是正则化参数, 这两个参数是本文要实现自适应估计的参数。根据偏差准则,  $\mathbf{B}$  的最优解存在于集合  $\mathbf{S}_1$  中,  $\mathbf{S}_1 = \{ \mathbf{B}; \|\mathbf{O} - \mathbf{B} - \mathbf{M}\|_2^2 \leq c \}$ ;  $\mathbf{M}$  的最优解存在于集合  $\mathbf{S}_2$  中,  $\mathbf{S}_2 = \{ \mathbf{M}; \|\mathbf{O} - \mathbf{B} - \mathbf{M}\|_2^2 \leq c \}$ 。

引入辅助变量  $\mathbf{A} = \mathbf{B}$ , 则将上式转化为如下问题, 即

$$\min_{\mathbf{B}, \mathbf{M}, \mathbf{A}} \left\{ \|\mathbf{A}\|_{\text{HOSVD}} + \frac{1}{\lambda} \|\mathbf{M}\|_1 + \frac{\mu}{2} \|\mathbf{O} - \mathbf{B} - \mathbf{M}\|_2^2 \right\} \quad (10)$$

s. t.  $\mathbf{A} = \mathbf{B}$ 。

根据拉格朗日定理, 上述有约束优化问题的拉格朗日函数为

$$L(\mathbf{A}, \mathbf{B}, \mathbf{M}, \mathbf{Y}_1, \lambda, \mu) = \|\mathbf{A}\|_{\text{HOSVD}} + \frac{1}{\lambda} \|\mathbf{M}\|_1 +$$

$$\frac{\mu}{2} \|\mathbf{O} - \mathbf{B} - \mathbf{M}\|_2^2 + \langle \mathbf{Y}_1, \mathbf{A} - \mathbf{B} \rangle + \frac{\beta_1}{2} \|\mathbf{A} - \mathbf{B}\|_2^2 \quad (11)$$

式中： $Y_1$  是拉格朗日乘子； $\beta_1$  是正的惩罚参数。本文采用 ADMM 来求解上述问题，采用偏差准则，推导出参数  $\lambda$  和  $\mu$  的更新公式，每一次迭代中，随其他变量的更新，参数  $\lambda$  和  $\mu$  也会按照固定的规律不断更新，直到算法终止。将上述问题分解为以下几个子问题求解，每次迭代中固定其他变量只更新一个变量，迭代步骤如下。

1) 固定其他变量，更新变量  $A$ 。

$$A^{(k+1)} = \arg \min_A \left\{ \|A\|_{\text{HOSVD}} + \langle Y_1, A - B^{(k)} \rangle + \frac{\beta_1}{2} \|A - B^{(k)}\|_2^2 \right\} = \arg \min_A \left\{ \|A\|_{\text{HOSVD}} + \frac{\beta_1}{2} \left\| A - \left( B^{(k)} - \frac{Y_1^{(k)}}{\beta_1} \right) \right\|_2^2 \right\} \quad (12)$$

对奇异值阈值收缩进行张量扩展，通过如下 3 个步骤求得式(12)的最优解。

① 张量分解求核张量  $S$ ，令  $H = B^{(k)} - Y_1^{(k)}/\beta_1$ ，根据式(7)HOSVD 的原理可通过下式求出

$$S = H \times_1 (U^{(1)})^T \times_2 (U^{(2)})^T \times_3 (U^{(3)})^T; \quad (13)$$

② 对  $S$  进行软阈值收缩；

③ 张量重建

$$A^{(k+1)} = \tilde{S} \times_1 U^{(1)} \times_2 U^{(2)} \times_3 U^{(3)}. \quad (14)$$

2) 更新变量  $B$  和  $\mu$ 。

$$B^{(k+1)} = \arg \min_B \left\{ \frac{\mu^{(k+1)}}{2} \|O - B - M^{(k)}\|_2^2 + \langle Y_1^{(k)}, A^{(k+1)} - B \rangle + \frac{\beta_1}{2} \|A^{(k+1)} - B\|_2^2 \right\} = \arg \min_B \left\{ \frac{\mu^{(k+1)}}{2} \|O - B - M^{(k)}\|_2^2 + \frac{\beta_1}{2} \left\| A^{(k+1)} - B + \frac{Y_1^{(k)}}{\beta_1} \right\|_2^2 \right\} \quad (15)$$

对式(15)右边  $B$  求导，令求导后的式子为 0，可得

$$B^{(k+1)} = \frac{\mu^{(k+1)}(O - M^{(k)}) + \beta_1 \left( A^{(k+1)} + \frac{Y_1^{(k)}}{\beta_1} \right)}{\mu^{(k+1)} + \beta_1}. \quad (16)$$

根据 Morozov's 偏差准则， $B$  的最优解存在于  $S_1$  中， $S_1 = \{B: \|O - B^{(k+1)} - M^{(k)}\|_2^2 \leq c^{(k+1)}\}$ 。从上述表达式中可以看出， $B$  是与  $\mu$  相关的变量，用  $B^*(\mu)$  表示式(11)对应的最优解，则有  $B^*(0) \in S_1, \mu = 0$  或者  $\|O - M^{(k)} - B^{(k+1)}\|_2^2 = c^{(k+1)}, \mu > 0$ ，即

$$c^{(k+1)} = \tau I_1 I_2 I_3 (\sigma^{(k+1)})^2. \quad (17)$$

根据上文可得

$$\sigma^{(k+1)} = 1.4826 \text{MAD}(\text{real}(B_{\text{HMM}}^{(k)})) \quad (18)$$

式中， $B_{\text{HMM}}^{(k)}$  为  $B^{(k)}$  在小波域中的最高频系数<sup>[13]</sup>。

如果

$$\left\| O - M^{(k)} - \left( A^{(k+1)} + \frac{Y_1^{(k)}}{\beta_1} \right) \right\|_2^2 \leq c^{(k+1)}, \quad (19)$$

$B^*(0) \in S_1, \mu = 0$ ，即

$$\begin{cases} \mu^{(k+1)} = 0 \\ B^{(k+1)} = A^{(k+1)} + Y_1^{(k)}/\beta_1 \end{cases} \quad (20)$$

如果

$$\left\| O - M^{(k)} - \left( A^{(k+1)} + \frac{Y_1^{(k)}}{\beta_1} \right) \right\|_2^2 > c^{(k+1)} \quad (21)$$

$$\|O - M^{(k)} - B^{(k+1)}\|_2^2 = c^{(k+1)}, \mu > 0, \text{ 即}$$

$$\left\| O - M^{(k)} - \frac{\mu^{(k+1)}(O - M^{(k)}) + \beta_1 \left( A^{(k+1)} + \frac{Y_1^{(k)}}{\beta_1} \right)}{\mu^{(k+1)} + \beta_1} \right\|_2^2 = c^{(k+1)} \quad (22)$$

$$\mu^{(k+1)} = \frac{\|\beta_1(O - M^{(k)} - A^{(k+1)}) - Y_1^{(k)}\|_2}{\sqrt{c^{(k+1)}}} - \beta_1. \quad (23)$$

因此，每次迭代中  $\mu$  的解根据  $A^{(k+1)} + Y_1^{(k)}/\beta_1$  的范围存在式(19)和式(21)两种情况。求出  $\mu$  的值后，再将  $\mu^{(k+1)}$  代入式(16)求  $B^{(k+1)}$  的值。

更新变量  $M$ ，这里引入辅助变量  $E = M$ ，即

$$\min_{M, E} \left\{ \frac{1}{\lambda} \|E\|_1 + \frac{\mu}{2} \|O - B - M\|_2^2 \right\} \quad (24)$$

s. t.  $E = M$ 。

根据拉格朗日定理，上述有约束优化问题的拉格朗日函数为

$$L(M, E, Y_2, \lambda, \beta_2) = \|E\|_1 + \frac{\mu\lambda}{2} \|O - B - M\|_2^2 + \langle Y_2, E - M \rangle + \frac{\beta_2}{2} \|E - M\|_2^2 \quad (25)$$

式中： $Y_2$  是拉格朗日乘子； $\beta_2$  是正的惩罚参数。

3) 更新变量  $E$ 。

$$E^{(k+1)} = \arg \min_E \left\{ \|E\|_1 + \langle Y_2^{(k)}, E - M^{(k)} \rangle + \frac{\beta_2}{2} \|E - M^{(k)}\|_2^2 \right\} = \arg \min_E \left\{ \|E\|_1 + \frac{\beta_2}{2} \left\| E - \left( M^{(k)} - \frac{Y_2^{(k)}}{\beta_2} \right) \right\|_2^2 \right\}. \quad (26)$$

可通过软阈值收缩算子  $S_{\alpha}(Z)$  求得最优解

$$E^{(k+1)} = S_{\beta_2} \left( M^{(k)} - Y_2^{(k)}/\beta_2 \right). \quad (27)$$

4) 同步骤 2)，更新变量  $M$  和  $\lambda$ 。

5) 更新拉格朗日乘子  $Y_1^{(k+1)}, Y_2^{(k+1)}$ 。

$$Y_1^{(k+1)} = Y_1^{(k)} + \beta_1 (A^{(k+1)} - B^{(k+1)}) \quad (28)$$

$$Y_2^{(k+1)} = Y_2^{(k)} + \beta_2 (E^{(k+1)} - M^{(k+1)}). \quad (29)$$

6) 判断终止条件。

$$\|M^{(k+1)} - M^{(k)}\|_2^2 / \|M^{(k)}\|_2^2 < t_{\text{tol}} \quad (30)$$

若式(30)满足或者达到最大迭代次数，则终止迭代。

7) 输出表示背景的  $B^{(k+1)}$ 、表示运动目标的  $M^{(k+1)}$ ；最后对输出的运动目标部分  $M$  进行二值化处理，得运动目标  $G$  为

$$G(x, y, t) = \begin{cases} 255 & M^{(k+1)}(x, y, t) \geq \varepsilon \\ 0 & \text{其他} \end{cases} \quad (31)$$

然后进一步对  $G$  进行形态学中开闭运算，消除运动目标区域外的噪声，填充目标区域内的空洞，最终提取较准确的运动目标。

### 3 实验结果及分析

#### 3.1 实验结果

本文数据是从标准的 change detection video database (<http://www.changedetection.net>) 数据库中选择 4 组真实视频序列进行测试,在相同实验环境下,本文方法与近期极具竞争力的鲁棒性主成分分析法(RPCA),以及基于迭代张量高阶奇异值分解(HOSVD)的运动目标提取方法进行比较。

视频 1 的图片像素大小为  $180 \times 120$ 。实验选取 80 帧进行测试,结果如图 1 所示。




图 1 视频 1 运动目标检测结果

Fig. 1 Moving target test results of Video 1

视频 2 的像素大小为  $240 \times 140$ 。实验中选取 80 帧进行测试,结果如图 2 所示。

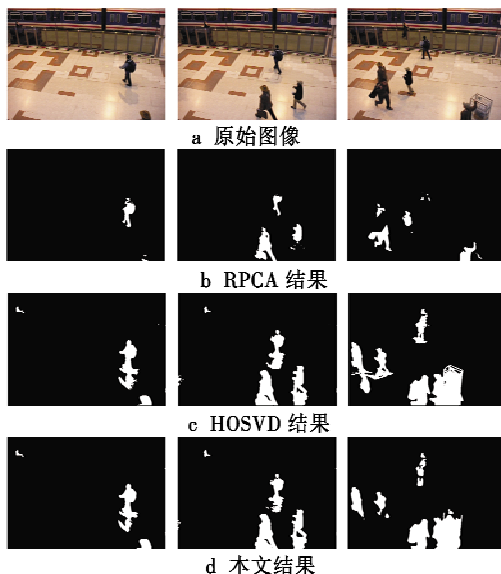


图 2 视频 2 运动目标检测结果

Fig. 2 Moving target test results of Video 2

视频 3 的像素大小为  $160 \times 120$ 。实验选取 80 帧进行测试,结果如图 3 所示。

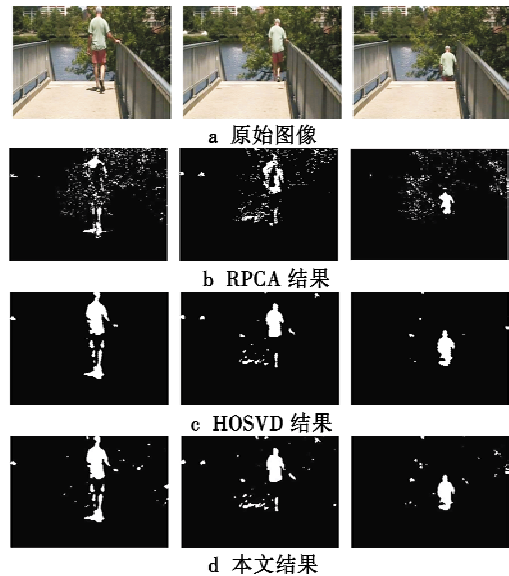


图 3 视频 3 运动目标检测结果

Fig. 3 Moving target test results of Video 3

视频 4 的像素大小为  $160 \times 120$ 。实验选取 80 帧进行测试,结果如图 4 所示。




图 4 视频 4 运动目标检测结果

Fig. 4 Moving target test results of Video 4

从实验结果可以看出,本文方法在多种场景下比 RPCA 的提取效果要好很多,与 HOSVD 方法结果差别不大,能较准确完整地提取运动目标。

#### 3.2 量化对比及结果分析

为量化评估算法提取运动目标的性能,本文采用召回率( $R_{\text{recall}}$ )、准确率( $P_{\text{precision}}$ )和两者的调和平均值 F-Measure 来衡量运动目标检测效果的好坏,即

$$\begin{cases} R_{\text{recall}} = TP / (TP + FN) \\ P_{\text{precision}} = TP / (TP + FP) \end{cases} \quad (32)$$



$$F = 2 \frac{P_{Precision} \cdot R_{recall}}{P_{Precision} + R_{recall}} \quad (33)$$

F-Measure 能够有效地维持  $R_{recall}$ ,  $P_{Precision}$  这两个标准的平衡, 依此评价标准, F-Measure 的大小和目标检测的效果成正比, 即 F-Measure 值越高, 目标检测的效果越好。

表 1 各个视频在不同算法下的结果指标

Table 1 Results of the videos in different algorithms

| 视频   | RPCA         |                 |           | HOSVD        |                 |           | 本文方法         |                 |           |
|------|--------------|-----------------|-----------|--------------|-----------------|-----------|--------------|-----------------|-----------|
|      | $R_{recall}$ | $P_{Precision}$ | F-Measure | $R_{recall}$ | $P_{Precision}$ | F-Measure | $R_{recall}$ | $P_{Precision}$ | F-Measure |
| 视频 1 | 0.6425       | 0.6217          | 0.6410    | 0.9528       | 0.9173          | 0.9347    | 0.9510       | 0.9241          | 0.9374    |
| 视频 2 | 0.6944       | 0.7048          | 0.6996    | 0.8266       | 0.8810          | 0.8529    | 0.8347       | 0.8940          | 0.8633    |
| 视频 3 | 0.5892       | 0.5029          | 0.5426    | 0.8977       | 0.8659          | 0.8815    | 0.8690       | 0.8572          | 0.8631    |
| 视频 4 | 0.4295       | 0.3617          | 0.3927    | 0.6873       | 0.7915          | 0.7357    | 0.6690       | 0.7621          | 0.7125    |
| 平均值  | 0.5916       | 0.6034          | 0.5483    | 0.8362       | 0.8609          | 0.8476    | 0.8262       | 0.8576          | 0.8411    |

图 5 展示了 8 组图像序列基于常规的 HOSVD 运动目标检测<sup>[14]</sup>的 F-Measure 指标随正则化参数  $\lambda$  变化的曲线图。对于不同的图像序列, 它们对应的最优参数都不同, 而且这 8 条曲线都很陡峭, 说明  $\lambda$  变化很快, F-Measure 值对  $\lambda$  比较敏感; 从变化范围看: 对于 8 个图像序列, 尽管  $\lambda$  的变化范围都很小, 在 0 ~ 0.04 之间, F-Measure 的值变化却很大, 变化范围从最小值 0 到最大值 1。




图 5 F-Measure 随  $\lambda$  变化曲线图

Fig. 5 The changing of F-Measure with  $\lambda$

综合上述实验数据可知: 1) 常规的 HOSVD 运动目标检测效果的好坏对正则化参数的变化极其敏感; 2) 针对不同的实验数据, 正则化参数的最优值都不同。由于这两个原因, 通过试错法手动调试正则化参数是一件极其困难的事, 需要通过大量的实验才能找到最优参数, 而本文方法能在不需要进行繁琐的手动调试参数的情况下, 取得和 HOSVD 方法几乎相同甚至更好的效果。

正则化参数不需要设置初值, 算法中上限  $c$  是已知的与噪声相关的数, 本文采用  $c = \tau I_1 I_2 I_3 \sigma^2$  来估计  $c$ 。  $\tau = 1$  是一个经验值, 当  $\tau = 2$  时, 目标检测效果最佳且该算法对惩罚参数  $\beta_1$  和  $\beta_2$  的值不敏感, 当它们的取值在较大范围内变动时, 实验结果变化不明显, 这里选择

分别计算各视频序列的  $R_{recall}$ ,  $P_{Precision}$  和 F-Measure, 从表 1 结果可以看出, 本文方法的  $R_{recall}$ ,  $P_{Precision}$  和 F-Measure 都比 RPCA 方法高。实验结果证明本文方法提取运动目标更为准确, 且能在不需要进行繁琐的手动调试参数的情况下, 取得和 HOSVD 方法几乎相同甚至更好的效果。

$$\beta_1 = \beta_2 = 3 \times 10^{-3}.$$

#### 4 结束语

本文提出了一种基于正则化参数自适应估计和 HOSVD 的运动目标提取方法。以 Morozov's 偏差准则为理论基础, 根据误差水平对正则化参数进行选择和调整。实验结果证明, 本文方法能很好地实现运动目标提取, 并且节省了大量的调试参数的时间。但由于模型的局限性, 在动态背景干扰很大时提取效果还不理想。因此在未来的工作中, 将继续优化本文模型和算法, 建立鲁棒性更强的优化模型并找到简洁、高效的奇异值分解算法, 使之能更好地去除动态背景带来的剧烈干扰。

#### 参考文献

- [1] BOUWMANS T, ZAHZAH E H. Robust PCA via principal component pursuit; a review for a comparative evaluation in video surveillance [J]. Computer Vision & Image Understanding, 2014, 122(4): 22-34.
- [2] LANG S N, ZHAO B, LIU X J, et al. A new image processing method for discriminating internal layers from radio echo sounding data of ice sheets via a combined robust principal component analysis and total variation approach [J]. Science China Technological Sciences, 2014, 57(4): 838-846.
- [3] JOHN W, ARVIND G, SHANKAR R, et al. Robust principal component analysis; exact recovery of corrupted low-rank matrices by convex optimization [C] // Proceedings of Neural Information Processing Systems, Whistler: MIT Press, 2009: 126-143.




图5 不同跟踪序列比例下的误识别率

Fig.5 False recognition rate under different rates of tracking sequence

由以上仿真实验结果可以看出,搜索序列相似度  $P_m$  均在90%以上,而误识别率  $P_f$  控制在了16%以下。

由图4和图5对比可知:在待对比序列的搜索模式序列类型一定时,序列长度对搜索序列相似度  $P_m$  和误识别率  $P_f$  几乎没有影响;而在跟踪模式比例一定时,跟踪模式的类型数越多,识别的序列相似度  $P_m$  越高,误识别率  $P_f$  越低;在跟踪模式的类型数一定时,跟踪模式比例越低,识别的序列相似度  $P_m$  越高,误识别率  $P_f$  越低。这是由于同样跟踪模式比例下,跟踪模式类型数越多,跟踪模式相同的机率就越低,从而使得序列相似度  $P_m$  越高,误识别率  $P_f$  越低;而跟踪模式类型

数相同时,跟踪模式比例越高,跟踪模式相同的机率就越高,使得序列相似度  $P_m$  越低,误识别率  $P_f$  越高。

## 5 结束语

本文分析了电子扫描雷达的工作过程和状态转换,通过对两个来自同一个雷达辐射源的状态转换序列进行公共序列提取,识别电子扫描雷达的主干工作模式序列,实现对电子扫描雷达工作模式的识别,并通过仿真分析研究了影响序列相似度  $P_m$  和误识别率  $P_f$  的因素。

## 参考文献

- [1] 陈艺廷,李鸿,李莹.基于句法模式识别的雷达识别方法研究[J].现代电子技术,2014,37(5):25-28.
- [2] 马爽,王莹桂,柳征,等.基于序列比对的多功能雷达搜索规律识别方法[J].电子学报,2012,40(7):1434-1439.
- [3] 李辉,郑坤,金炜东,等.基于多层次建模的机载相控阵雷达工作模式识别[J].电子信息对抗技术,2016,31(4):1-5,42.
- [4] 冀琛,潘谊春,郁春来,等.对相控阵雷达工作模式的资源调度研究[J].现代防御技术,2014,42(3):20-24.
- [5] DONOHO D L, JOHNSTONE J M. Ideal spatial adaptation by wavelet shrinkage[J]. Biometrika, 1994, 81(3):425-455.
- [6] 张义昕,张海,吴平.改进的二阶互差分测量噪声方差估计算法[J].电光与控制,2016,23(8):13-17,38.
- [7] WU G, LUO S. Adaptive fixed-point iterative shrinkage/thresholding algorithm for MR imaging reconstruction using compressed sensing[J]. Magnetic Resonance Imaging, 2014, 32(4):372-378.
- [8] RAJWADE A, RANGARAJAN A, BANERJEE A. Image denoising using the higher order singular value decomposition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2013, 35(4):849-862.
- [9] 刘刚,周珩,王忠勇,等.空域-小波域联合滤波的红外复杂背景抑制[J].电光与控制,2015,22(5):37-40,45.
- [10] 徐联微,杨晓梅.基于迭代张量高阶奇异值分解的运动目标检测[J].计算机应用研究,2016,33(9):2856-2861.
- [11] XU Y Y. Fast algorithms for higher-order singular value decomposition from incomplete data[J]. Journal of Computational Mathematics, 2017, 35(4):397-422.
- [12] ZHANG X J, JAVIDI B, NG M K, et al. Automatic regularization parameter selection by generalized cross-validation for total variational poisson noise removal[J]. Applied Optics, 2017, 56(9):47-56.
- [13] XU Y B, PEI Y, DONG F. An extended L-curve method for choosing a regularization parameter in electrical resistance tomography[J]. Measurement Science & Technology, 2016, 27(9):63-74.
- [14] 姚智颖,刘冬,刘光斌.具有新目标函数的改进型变分贝叶斯[J].电光与控制,2011,18(8):45-46,55.
- [15] FERMIN S, VIIOCHE B. Simple and efficient determination of the Tikhonov regularization parameter chosen by the generalized discrepancy principle for discrete ill-posed problems[J]. Journal of Scientific Computing, 2015, 63(1):163-184.

(上接第83页)