

加权截断 p 范数在运动目标检测中的应用

宣 晓, 余 勤

(四川大学 电气信息学院, 成都 610065)

摘 要: 在基于稀疏低秩分解的运动目标检测方法中, 由于核范数并非为矩阵的秩函数最佳近似, 未考虑到运动目标的空间连续性, 在动态背景干扰的情况下, 运动目标检测的效果不理想。针对上述问题, 提出加权截断 p 范数分析模型。该模型将观测视频分为静态背景、运动目标与动态背景 3 个部分, 静态背景采用改进的非凸范数, 即加权截断 p 范数进行低秩约束, 根据动态背景与运动目标具有空间连续性的特点, 分别使用 $l_{2,1}$ 范数进行结构性稀疏约束。实验结果表明, 与鲁棒主成分分析模型、截断核范数模型、加权核范数模型以及相邻离群点低秩模型相比, 该模型可有效去除动态背景扰动, 并能提取到更精确的运动目标。

关键词: 背景建模; 运动目标提取; 稀疏与低秩理论; 加权截断 p 范数; 结构性稀疏范数

中文引用格式: 宣 晓, 余 勤. 加权截断 p 范数在运动目标检测中的应用[J]. 计算机工程, 2018, 44(6): 233-238, 248.

英文引用格式: XUAN Xiao, YU Qin. Application of weighted truncated p norm in motion target detection[J]. Computer Engineering, 2018, 44(6): 233-238, 248.

Application of Weighted Truncated p Norm in Motion Target Detection

XUAN Xiao, YU Qin

(School of Electrical and Information, Sichuan University, Chengdu 610065, China)

[Abstract] In the moving object detection methods base on low rank and sparse decomposition, the nuclear norm is not the best approximation of the rank function of the matrix, meanwhile, the spatial continuity of moving object is not to be considered. As a result, the effect of moving object detection isn't ideal on the circumstance of dynamic interference. To deal with this problem, a model named weighted truncated p -norm model is proposed. This model divides the observed video into three parts: the static background, the moving object and the dynamic background. The static background is constrained by an improved non-convex norm——weighted truncated p -norm. And according to the characteristic of spatial continuity, the dynamic background and moving object are constrained by structured-sparse $l_{2,1}$ -norm, respectively. Experimental results show that the WTPR model can remove noise of dynamic background effectively, also the more accurate moving object can be obtained than Robust Principal Component Analysis (RPCA)、Truncated Nuclear Norm Regularization (TNNR)、Weighted Nuclear Norm Minimization (WNNM)、Detecting Contiguous Outliers in the Low-rank Representation (DECOLOR).

[Key words] background modeling; moving target extraction; sparse and low rank theory; weighted truncated p norm; structured-sparse norm

DOI: 10.19678/j.issn.1000-3428.0047126

0 概述

运动目标检测是机器视觉中监视^[1]与跟踪^[2]的重要技术, 常见的检测方法有光流法^[3]、帧差法^[4]和背景建模法^[5]。背景建模法具有计算量少, 运行速度快的优点受到广泛关注。随着稀疏与低秩理论的提出, 文献[6]提出了鲁棒主成分分析模型 (Robust Principal Component Analysis, RPCA), 该模型利用底层低秩结构将由视频组成的观测大矩阵分解为稀疏的运动目标和低秩的背景两部分, 在假设

背景是相对静止的情况下能有效进行背景建模, 从而提取出运动目标。

然而 RPCA 模型在实际检测中并非为最优模型, 近年来学者们对该模型进行了优化: 文献[7]提出了结合运动显著性估计的一种层次化的双行程 RPCA 模型进行前景检测; 文献[8]提出了自适应的 $l_{2,1}$ 范数对稀疏部分进行优化; 文献[9]提出了相邻离群点的低秩表示模型 (Detecting Contiguous Outliers in the Low-Rank Representation, DECOLOR), 利用马尔科夫随机场结合邻近先验知识保证运动目

作者简介: 宣 晓 (1992—), 女, 硕士研究生, 主研方向为数字图像处理; 余 勤, 副教授、硕士。

收稿日期: 2017-05-09 **修回日期:** 2017-06-14 **E-mail:** xuanxiaol204@126.com

标连续性,这些改进后的方法一定程度上提高了对运动部分的提取精度。为更精确的对低秩背景进行建模,文献[10]提出截断核范数模型(Truncated Nuclear Norm Regularization, TNNR),通过去除较大的前 r 个奇异值减少由奇异值差别过大对低秩部分的影响,改善了背景恢复的效果;文献[11]提出加权核范数模型(Weighted Nuclear Norm Minimization, WNNM),通过加权改变奇异值的大小改善背景恢复的效果,这 2 种方法一定程度上提高了背景建模的效果,但本质上均是对核范数进行变形。从理论上,矩阵的秩函数为非零奇异值的个数,每个奇异值对秩的影响等价;而核范数定义为所有奇异值之和,每个奇异值对秩的影响不同,因此核范数并非为矩阵低秩部分的最佳近似,为寻找到一种更优的非凸最小化近似,文献[12]提出 Schatten- p 范数模型,并证明了 Schatten- p 范数比传统的核范数能更好的逼近原始的秩,可以得到更理想的背景模型。

在实际生活中受到树叶摇晃、湍流扰动、光线变化等影响,背景是处于动态变化的,这对背景建模产生一定程度的影响。考虑到目前尚没有一种有效的稀疏低秩模型能克服动态背景带来的扰动,以进行有效的运动目标检测,本文结合文献[10]的截断核范数及文献[12]的 Schatten- p 范数,提出一种新的截断加权 p 范数,并专门针对动态背景稀疏的特点,给出改进的稀疏低秩模型。

1 本文模型的建立

1.1 加权截断 p 范数分析模型的建立

本文提出了一种针对动态背景进行运动目标检测的鲁棒的稀疏低秩模型—加权截断 p 范数分析模型(Weighted Truncated p Norm, WTPN),该模型如下:

$$\begin{aligned} \min \quad & \|L\|_{w,r}^p + \lambda_1 \|S\|_1 + \kappa \lambda_2 \|F\|_{2,1} + \\ & \kappa(1-\lambda_2) \|E\|_{2,1} \\ \text{s.t.} \quad & D = L + S, S = E + F \end{aligned} \quad (1)$$

其中,矩阵 D 为输入视频,矩阵 L 为视频中的静态部分,矩阵 S 为视频中的动态部分,矩阵 F 为动态部分中的运动目标,矩阵 E 为动态部分中的动态背景扰动。 $\|\cdot\|_{w,r}^p$ 为加权截断 p 范数, $\|L\|_{w,r}^p$ 表示采用加权截断 p 范数对静态部分低秩矩阵 L 进行约束, $\lambda_1 \|S\|_1 + \kappa \lambda_2 \|F\|_{2,1} + \kappa(1-\lambda_2) \|E\|_{2,1}$ 表示采用稀疏 l_1 范数及结构性稀疏约束的 $l_{2,1}$ 范数对稀疏的动态部分进行约束,下面将分别详细介绍各个部分的具体含义。

1.1.1 低秩背景部分矩阵估计

低秩部分使用截断加权 p 范数模型进行低秩矩阵估计,通过去掉前 r 个最大的奇异值,并对后 $\min(m, n) - r$ 个奇异值进行加权的思想,使用非凸近似的方法,更精确地刻画出矩阵的秩。该模型定义

如下:

$$\|L\|_{w,r}^p = \left[\sum_{i=1}^{\min(m,n)} \omega_i \sigma_i^p(L) \right]^{\frac{1}{p}} \quad (2)$$

其中, σ_i 为矩阵 L 的第 i 个奇异值, $\min(m, n)$ 为矩阵的秩, $p(0 < p \leq 1)$ 为加权截断 p 范数的参数, ω_i 为奇异值的权重, r 为截断阈值。

不同 p 值下加权截断 p 范数的取值也不同,令 $\omega_i = 1, r = 1$, 可得:

$$\|L\|_{1,1}^p = \sum_{i=1}^{\min(m,n)} \sigma_i^p(L) \quad (3)$$

当 $p = 0$ 时,式(3)即为矩阵 L 的秩函数, $p = 1$ 时,式(3)即为核范数。将其分别取不同的 p 值,由图 1 可以看出,当 p 越逼近 0,则加权截断 p 范数比核范数更逼近矩阵的秩。




图 1 不同 p 值下 p 范数取值

权重 ω_i 需要根据低秩矩阵 L 奇异值的大小进行改变,由于越大的奇异值对低秩矩阵的影响越大,因此需要设计一个自适应权重更新公式使得权重与奇异值的大小成反比,加权后的奇异值大小近似相等。根据文献[13]给出的权值方程,本文给出权重的更新方程如下:

$$\omega_i = 2C \sqrt{mn} / (\sigma_i^{\frac{1}{p}}(\hat{L}) + \varepsilon) \quad (4)$$

其中, $C = 10^{1/p}$, $\varepsilon = 10^{-16}$ 为给定的最优值,矩阵 $\hat{L}$ 为权重估计矩阵, $\sigma_i(\hat{L})$ 为权重估计矩阵的第 i 个奇异值。权重估计矩阵需引入初始化公式由输入矩阵 L 间接进行推导,初始化公式如下:

$$\sigma_i(\hat{L}) = \sqrt{\max\{\sigma_i^2(L) - 2\sqrt{mn}, 0\}} \quad (5)$$

对截断阈值 r 的选择,考虑到低秩背景变化不大,因此,设置截断阈值 $r = 1$ 即可保证低秩背景恢复效果最好。

1.1.2 稀疏前景部分矩阵估计

加权截断 p 范数分析模型中,由于动态部分既包括所要提取的运动目标,还包括受树叶晃动,水波纹等产生的动态背景,因此将稀疏部分矩阵 S 进一步分解为动态背景矩阵 E 与运动目标矩阵 F ,可得:

$$\begin{aligned} \min \quad & \lambda_1 \|S\|_1 + \kappa \lambda_2 \|F\|_{2,1} + \kappa(1-\lambda_2) \|E\|_{2,1} \\ \text{s.t.} \quad & D = L + S, S = E + F \end{aligned} \quad (6)$$

首先使用 l_1 范数将矩阵中的稀疏部分矩阵 S 进

行粗提取,其次根据运动的物体在空间上具有连续性的特点,使用比 l_1 范数更具有结构稀疏性的 $l_{2,1}$ 范数分别约束动态部分中的动态背景矩阵 E 与运动目标矩阵 F 。

由于在提取运动目标的同时需要对背景扰动进行抑制,因此使用 $\kappa\lambda_2$ 和 $\kappa(1-\lambda_2)$ 分别对矩阵 F 和 E 进行正则化约束,可以达到在对运动目标进行提取的同时抑制动态背景干扰的目的。

2 模型的求解

求解加权截断 p 范数分析模型(WTPN)可采用增广拉格朗日乘子法^[14](Augmented Lagrangian Method, ALM)进行求解,引入拉格朗日乘子 X, Y , 构造出的增广拉格朗日函数如下:

$$\begin{aligned} \mathcal{L}(L, S, E, F, X, Y) = & \|L\|_{w,r}^p + \lambda_1 \|S\|_1 + \kappa\lambda_2 \|F\|_{2,1} + \kappa(1-\lambda_2) \|E\|_{2,1} + \\ & \langle X, D-L-S \rangle + \mu_1 (\|D-L-S\|_F^2)/2 + \\ & \langle Y, S-E-F \rangle + \mu_2 (\|S-E-F\|_F^2)/2 \end{aligned} \quad (7)$$

其中, μ_1, μ_2 为惩罚因子,目标函数可通过交替方向法^[15](Alternating Direction Method, ADM)分别进行求解更新。

固定矩阵 S, E, F , 更新矩阵 L 。加权截断 p 范数的求解参考文献[10]中的两步迭代算法,可转化为对加权 p 范数进行求解,化简方程如下:

$$\begin{aligned} \|L\|_{w,r}^p &= \left(\sum_{i=r}^{\min(m,n)} \omega_i \sigma_i^p(L) \right)^{\frac{1}{p}} = \\ & \left(\sum_{i=1}^{\min(m,n)} \omega_i \sigma_i^p(L) \right)^{\frac{1}{p}} - \left(\sum_{i=1}^r \omega_i \sigma_i^p(L) \right)^{\frac{1}{p}} = \\ & \|L\|_w^p - \max_{AA^T=I_{r \times r}, BB^T=I_{r \times r}} \text{Tr}(A_r L B_r^T) \end{aligned} \quad (8)$$

其中, A_r 为左奇异特征向量, B_r 为右奇异特征向量。则 L 的更新表达式可写为:

$$\begin{aligned} L_{k+1} &= \arg \min_L \|L\|_w^p + \\ & \mu_{1,k} (\|L - (D - S_{k+1} + (X_k + A_r^T B_r))\|_F^2)/2 \end{aligned} \quad (9)$$

通过广义软阈值算法^[13](Generalized Soft Threshold, GST)进行可求解式(9)。通过已知的参数 $p(0 < p \leq 1)$ 和权重 ω_i , 得到阈值 τ_p^{GST} 如下:

$$\tau_p^{\text{GST}}(\omega_i) = (2\omega_i(1-p))^{\frac{1}{2-p}} + \omega_i p (2\omega_i(1-p))^{\frac{p-1}{2-p}} \quad (10)$$

则广义软阈值收缩方程如下:

$$\begin{cases} \tilde{\delta}_i - \sigma_i + \omega_i p (\tilde{\delta}_i)^{p-1} = 0, \sigma_i \geq \tau_p^{\text{GST}}(\omega_i) \\ \tilde{\delta}_i = 0, \sigma_i < \tau_p^{\text{GST}}(\omega_i) \end{cases} \quad (11)$$

其中, σ_i 为低秩矩阵 L 的第 i 个奇异值, $\tilde{\delta}_i$ 为待求的加权低秩矩阵第 i 个奇异值。阈值 $\tau_p^{\text{GST}}(\omega_i)$ 的推导过程详见参考文献[10], 算法流程参见算法1。

固定矩阵 L, F, E , 稀疏矩阵 S 通过最速下降法

及软阈值收缩,求得更新方程如下:

$$S_{k+1} = S_{\lambda/\mu_{1,k}}[(D - L_{k+1} + E_k + F_k)/2 + (X_k - Y_k)/2\mu_{1,k}] \quad (12)$$

固定矩阵 L, S, E , 运动目标矩阵 F 的更新如下:

$$\begin{aligned} F_{k+1} &= \arg \min_F \kappa\lambda_2 \|F\|_{2,1} + \\ & \mu_{2,k} (\|F - (S_{k+1} - E_k + Y_k/\mu_{2,k})\|_F^2)/2 \end{aligned} \quad (13)$$

通过阈值收缩算子 $T_\eta[\cdot]$ 求得式(13)的最优解, 阈值收缩方程如下:

$$T_\eta[Z] = Z \cdot \max(0, 1 - \eta/\|Z\|_2) \quad (14)$$

其中, Z 为输入矩阵, η 为收缩系数, 则运动目标矩阵 F 的更新方程如下:

$$F_{k+1} = T_{\kappa\lambda_2/\mu_{2,k}}(S_{k+1} - E_k + Y_k/\mu_{2,k}) \quad (15)$$

同理, 固定矩阵 L, S, F , 动态背景矩阵 E 的更新方程如下:

$$E_{k+1} = T_{\kappa(1-\lambda_2)/\mu_{2,k}}(S_{k+1} - F_{k+1} + Y_k/\mu_{2,k}) \quad (16)$$

最后分别更新拉格朗日乘子 X, Y 与惩罚系数 μ_1, μ_2 如下:

$$X_{k+1} = X_k + \mu_{1,k}(D - L_{k+1} - S_{k+1}) \quad (17)$$

$$Y_{k+1} = Y_k + \mu_{2,k}(S_{k+1} - E_{k+1} - F_{k+1}) \quad (18)$$

$$\mu_{1,k+1} = \min(\rho\mu_{1,k}, \mu_{\max}) \quad (19)$$

$$\mu_{2,k+1} = \min(\rho\mu_{2,k}, \mu_{\max}) \quad (20)$$

直到求解算法收敛则迭代停止。

算法1 广义软阈值算法(GST)流程

输入 $D - S_{k+1} + (X_k + A_r^T B_r)$, p 和 ω

输出 L

1. $U\Sigma V^T = D - S_{k+1} + (X_k + A_r^T B_r)$, $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$;

2. $\tau_p^{\text{GST}} = (2\omega(1-p))^{\frac{1}{2-p}} + \omega p (2\omega(1-p))^{\frac{p-1}{2-p}}$;

3. for $i = 1, 2, \dots, \min(m, n)$

4. if $\Sigma_i < \tau_p^{\text{GST}}$ then

5. $\tilde{\delta}_i = 0$

6. else

7. $\tilde{\delta}_i = |\Sigma_i| - \omega_i p (\tilde{\delta}_i)^{p-1}$;

8. end if

9. end

10. $\Delta = \text{diag}(\tilde{\delta}_1, \tilde{\delta}_2, \dots, \tilde{\delta}_r)$

11. $L = U\Delta V^T$

3 实验结果与分析

3.1 参数 p 选择

为得到最优的参数 $p(0 < p \leq 1)$, 将 WTPR 模型中的 p 值选取为: 0.25, 0.5, 0.75, 1 与使用核范数的 RPCA 模型进行对低秩矩阵 L 部分恢复效果的对比, 实验采用文献[16]中的运动目标检测数据库 Change Detection Viedo Database 中的 5 组测试视频: highway、boats、canoe、fountain02、overpass 通过均方根

误差 R_{RMSE} 进行误差对比,均方根误差公式如下:

$$R_{RMSE} = \frac{\|L - L_0\|_F^2}{\|L_0\|_F^2} \quad (21)$$

其中,矩阵 L 为实验恢复出的背景图像,矩阵 L_0 为真实背景图像,均方根误差越小,则恢复效果

越好。结果如表 1 所示,加粗部分为实验结果最佳值,从表 1 可看出,使用加权截断 p 范数的 WTPN 模型比使用核范数的 RPCA 模型的均方根误差更小,证明加权截断 p 范数在背景恢复中效果更好。

表 1 不同 p 值下 WTPN 与 RPCA 均方根误差对比

测试集名称	本文 WTPN 模型				RPCA 模型
	$p = 0.25$	$p = 0.50$	$p = 0.75$	$p = 1$	
highway	0.075 4	0.075 4	0.075 5	0.093 2	0.078 9
boats	0.073 7	0.073 7	0.073 4	0.077 4	0.088 9
canoe	0.134 9	0.134 9	0.139 8	0.142 0	0.157 9
fountain02	0.106 4	0.106 4	0.106 2	0.106 9	0.106 9
overpass	0.122 3	0.114 6	0.077 2	0.101 5	0.150 4

在动态背景扰动不明显的 highway 视频中,参数 p 选择 0.25 时效果最好,而在动态背景扰动明显的后 4 组视频中,参数 p 值得选取在 0.75 左右时效果最好,产生不同结果的原因在于本文模型针对背景扰动对奇异值进行了的加权与截断,同时对稀疏部分进行了成分分解。因此,在动态背景扰动不明显得情况下, p 值选择越小越好,而在背景扰动明显的情况下, p 值选择为 0.75 时,背景恢复效果最好。本文选取将 $p = 0.75$ 进行后续的实验。

3.2 实验仿真

本文分别通过不同视频之间与同一视频不同帧

数之间得到的结果来对比 WTPN 模型的检测效果。将其与 4 类代表性模型,即 RPCA^[6]、TNNR^[10]、WNNM^[11]、DECOLOR^[9] 进行比较。数据采用数据库 change detection viedo database^[16] 中的 4 组动态背景明显的 boats、canoe、fountain02、overpass 视频及 1 组动态背景不明显的 highway 视频进行仿真。仿真运行环境为 Intel Core i5-4430 处理器,2.70 GHz 主频,8 GB 内存,Win10 操作系统;软件采用 Matlab R2015a。得到的结果如图 2 所示。其中,第 1 列~第 7 列分别对应原始片段、Groundtruth、RPCA、TNNR、WNNM、DECOLOR、WTPN。




图 2 动态背景下各模型实验对比

3.2.1 动态背景下目标提取实验对比

由图 2 可知,本组实验从选取动态背景扰动明显的 4 组视频,即 boats、canoe、fountain02、overpass。实验结果表明,在船尾拖纹、水面波纹、喷泉遮挡及


树叶晃动的情况下,RPCA、TNNR、WNNM 模型得到的运动目标均存在由动态背景扰动产生的大量噪声;DECOLOR 模型提取出的运动目标错分严重并不能很好地保持运动物体的结构轮廓信息;本文

WTPN 模型较对比模型可以准确提取出运动目标,同时可以抑制大部分由动态背景产生的噪声。


3.2.2 不同帧数下目标提取实验对比

为对比在不同帧数下 WTPN 模型对于运动目标提取的效果,本组实验分别采用背景扰动不明显的

highway 视频与背景扰动明显的 canoe 视频,将测试集选取为 3 段不同帧数的视频进行对比,得到实验结果如图 3 所示。其中,第 1 列~第 7 列分别对应原始片段、Groundtruth、RPCA、TNNR、WNNM、DECOLOR、WTPN。



(a)highway视频第20帧、50帧、70帧所获取运动目标二值图



(b)canoe视频第50帧、80帧、95帧所获取运动目标二值图

图3 不同帧数下各模型运动目标提取效果对比

图 3(a) 实验为背景扰动不明显的 highway 视频,选取第 20 帧、50 帧和 70 帧进行对比。RPCA 模型存在较多的噪声,同时提取的目标不清楚。TNNR 与 WNNM 较 RPCA 模型目标提取效果较好,但运动目标产生了空洞及错分。DECOLOR 模型有效减少了噪声,但损失了很多运动目标的细节与轮廓信息。本文 WTPN 模型在整个视频处理过程中可以很好地抑制噪声,提取出准确完整的运动目标。

图 3(b) 实验在背景扰动明显的 canoe 视频中,采取第 55 帧、80 帧和 95 帧进行对比,由于水面波动较大,得出的运动目标二值图均存在噪声。通过对比可知,RPCA、TNNR、WNNM 模型得到的运动目标与背景错分严重且存在的噪声较多。DECOLOR 模型可抑制大部分的噪声,但在帧数较少的情况下不能准确地提取出运动目标,同时在全部的处理过程中提取出的运动目标错分现象较为严重。本文 WTPN 模型可以很好地抑制动态背景产生的噪声,

且提取出的运动目标基本没有错分现象。由此可以说明,本文 WTPN 模型在运动目标检测中,较对比模型 WTPN 模型在抑制动态背景噪声及提取运动目标的准确程度上具有一定的优势。

3.3 量化对比结果分析

为量化评估 WTPN 模型在运动目标检测中的效果,本文采用错分率 (Probability of Wrong Classify, PWC) 与峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 衡量运动目标提取及背景建模的质量:

$$P_{\text{PWC}} = \frac{FN + FP}{TP + TN + TP + TN} \quad (22)$$

$$P_{\text{PSNR}} = 10 \times \lg \left(\frac{(2^n - 1)^2}{M_{\text{MSE}}} \right) \quad (23)$$

其中, TP 、 TN 分别为被正确分类的前景像素点数和背景像素点数, FP 、 FN 分别被错误归为前景和被错误归为背景的像素点数, M_{MSE} 为原图像与处理图像之间的均方误差。在运动目标检测中 PWC 是检验

运动目标提取质量的重要指标,错分率越低,该方法的运动目标提取效果越好,PSNR 是检验背景建模好坏的常用的指标之一,峰值信噪比越高,背景恢复的效果越好。本文从数据库 Change Detection Viedo Database^[16]选取 9 组具有代表意义的视频进行实验,视频的具体信息如表 2 所示。

表 2 视频详细信息

视频名称	分辨率/像素	帧数	视频描述
boats	320 × 240	85	船只拖纹
canoe	320 × 240	100	水面波动,船只行驶缓慢
fountain02	432 × 288	85	喷泉及遮挡
overpass	320 × 240	85	树叶剧烈晃动
highway	320 × 240	70	树叶轻微晃动
blizzard	720 × 480	70	雨雪天气
pedestrains	360 × 240	75	基本无扰动
turbulence2	645 × 315	70	大气湍流影响
port_0_17fps	640 × 480	60	复杂背景下船只晃动

不同模型间的错分率 PWC 对比如表 3 所示,不同模型间的峰值信噪比 PSNR 对比如表 4 所示,加粗部分为实验结果最佳值。由表 3 及表 4 可以看出,本文 WTPN 模型在大部分动态背景扰动明显的视频中可获得更低的错分率及更高的峰值信噪比,运动目标检测效果更好。对于 turbulence2、pedestrains 这 2 个特殊的测试集,WTPN 的峰值信噪比低于 DECOLOR,经过分析可知,在 turbulence2 的湍流场景里,由于当背景扰动为湍流噪声时在空间中不具备连续性,因此本文模型可能并不适用;在 pedestrains 的无扰动场景里,背景是基本没有动态背景的,本文模型对该类视频在背景恢复上效果不是十分明显。

表 3 不同模型间错分率对比

测试集	RPCA	TNNR	DECOLOR	WNNM	本文 WTPN
boats	0.485	0.468	0.465	0.462	0.399
canoe	0.058	0.047	0.046	0.038	0.034
fountain02	0.109	0.055	0.091	0.056	0.045
overpass	0.004	0.005	0.019	0.005	0.004
highway	0.030	0.014	0.029	0.029	0.020
blizzard	0.005	0.005	0.031	0.005	0.004
pedestrains	0.015	0.012	0.003	0.001	0.001
turbulence2	0.495	0.494	0.492	0.519	0.490
port_0_17fp	0.485	0.468	0.465	0.462	0.399

表 4 不同模型间峰值信噪比对比 dB

测试集	RPCA	TNNR	DECOLOR	WNNM	本文 WTPN
boats	25.26	27.24	28.52	29.02	29.24
canoe	22.24	22.33	23.68	23.47	25.79
fountain02	26.67	26.40	26.64	26.42	28.68
overpass	24.32	25.75	28.63	25.10	28.91
highway	27.78	27.89	27.57	27.89	28.76
blizzard	36.18	36.34	36.36	36.62	36.73
pedestrains	26.81	26.80	26.88	26.85	26.77
turbulence2	34.30	34.21	34.30	34.31	34.30
port_0_17fp	17.10	17.16	17.18	17.14	17.72

从时间上来讲,DECOLOR 模型由于加入对前景目标的先验知识,导致运行时间过长而不能进行实时进行检测,本文模型采用加权截断 p 范数可在提供的测量数据较少的情况下仍能准确地检测出运动目标,运算时间上更加快速。因此,从整体上说本文 WTPN 模型要优于文中对比的其他 4 种对比模型,在运动目标检测领域不论从实验还是数据上均具有一定的优势。

4 结束语

本文针对动态背景下运动目标提取效果较差的问题,提出加权截断 p 范数分析模型 WTPN,使用截断加权 p 范数约束低秩部分,同时为抑制动态背景对运动目标检测的影响,采用将动态稀疏部分分解为运动目标及动态背景两部分的方法,使用具有结构性稀疏特点的 $l_{2,1}$ 范数进行约束。实验结果表明,本文 WTPN 模型较其他基于核范数的模型在运动目标检测方面的效果更好,适用于一般具有动态背景的视频如水面波动、树叶摇晃及复杂动态背景等。但考虑到运动目标具有时间及空间的连续性,因此,将引入时间与空间的显著性约束,从而进一步优化本文模型。

参考文献

- [1] 李庆忠,陈显华,王立红. 视频监控中运动目标检测与识别方法[J]. 计算机工程,2004,30(16):143-145.
- [2] 周圣鑫,周 军,宋 利,等. 一种针对小目标的跟踪算法[J]. 计算机工程,2010,36(16):186-188.
- [3] 袁 猛,陈 震,危水根,等. 一种改进的变分光流计算方法[J]. 计算机工程,2011,37(3):215-217.
- [4] 李秋林,何家峰. 基于三帧差法和交叉熵阈值法的车辆检测[J]. 计算机工程,2011,37(4):172-174.
- [5] 张明杰,康宝生. 一种两步高斯混合模型的运动目标检测方法[J]. 计算机工程,2015,41(10):245-249.

(下转第 248 页)

- [39] SU C C, CORMACK L K, BOVIK A C. Oriented correlation models of distorted natural images with application to natural stereopair quality evaluation[J]. IEEE Transactions on Image Processing, 2015, 24(5): 1685-1699.
- [40] APPINA B, KHAN S, CHANNAPPAYYA S S. No-reference stereoscopic image quality assessment using natural scene statistics[J]. Signal Processing: Image Communication, 2016, 43: 1-14.
- [41] LEE K, LEE S. 3D perception based quality pooling: Stereopsis, binocular rivalry, and binocular suppression[J]. IEEE Journal of Selected Topics in Signal Processing, 2015, 9(3): 533-545.
- [42] JUNG Y J, KIM H G, RO Y M. Critical binocular asymmetry measure for perceptual quality assessment of synthesized stereo 3D images in view synthesis[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2015, 26(7): 1201-1214.
- [43] LIN Y H, WU J L. Quality assessment of stereoscopic 3D image compression by binocular integration behaviors[J]. IEEE Transactions on Image Processing, 2014, 23(4): 1527-1542.
- [44] 宋 洋, 郁 梅, 彭宗举, 等. 基于双目信息融合的立体图像质量评价模型[J]. 光电子技术, 2014, 34(2): 102-105.
- [45] WANG J, REHMAN A, ZENG K, et al. Quality prediction of asymmetrically distorted stereoscopic 3D images[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3400-3414.
- [46] YANG Jiachen, LIU Yun, GAO Zhiqun, et al. A perceptual stereoscopic image quality assessment model accounting for binocular combination behavior[J]. Journal of Visual Communication Image Representation, 2015, 31: 138-145.
- [47] 顾珊波, 邵 枫, 蒋刚毅, 等. 基于支持向量回归的立体图像客观质量评价模型[J]. 电子与信息学报, 2012, 34(2): 369-374.
- [48] KIM H, LEE S. Transition of visual attention assessment in stereoscopic images with evaluation of subjective visual quality and discomfort[J]. IEEE Transactions on Multimedia, 2015, 17(12): 2198-2209.
- [49] SHAO Feng, LIN Weisi, JIANG Gangyi, et al. Models of monocular and binocular visual perception in quality assessment of stereoscopic images[J]. IEEE Transactions on Computational Imaging, 2016, 2(2): 123-135.
- [50] 桑庆兵, 谭红宝. 极端学习四元数小波特征的立体图像质量评价[J]. 光电子·激光, 2016, 27(6): 662-669.
- [51] SAHA A, WU Q M J. Utilizing image scales towards totally training free blind image quality assessment[J]. IEEE Transactions on Image Processing, 2015, 24(6): 1879-1892.
- [52] 田维军, 邵 枫, 蒋刚毅, 等. 基于深度学习的无参考立体图像质量评价[J]. 计算机辅助设计与图形学学报, 2016, 28(6): 968-975.

编辑 索书志

(上接第 238 页)

- [6] CANDES E J, LI X, MA Y, et al. Robust principal component analysis[J]. Journal of the ACM, 2009, 58(3): 11.
- [7] GAO Zhi, CHEONG Loong-Fah, SHAN Mo. Block-sparse RPCA for consistent foreground detection[C]//Proceedings of European Conference on Computer Vision. Berlin, Germany: Springer-Verlag, 2012: 690-703.
- [8] GUYON C, BOUWMANS T, ZAHZAH E H. Foreground detection based on low-rank and block-sparse matrix decomposition[C]//Proceedings of IEEE International Conference on Image Processing. Washington D. C., USA: IEEE Press, 2013: 1225-1228.
- [9] ZHOU Xiaowei, YANG Can, YU Weichuan. Moving object detection by detecting contiguous outliers in the low-rank representation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2013, 35(3): 597-610.
- [10] HU Yao, ZHANG Debing, YE Jieping, et al. Fast and accurate matrix completion via truncated nuclear norm regularization[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2013, 35(9): 2117-2130.
- [11] GU Shuhang, ZHANG Lei, ZUO Wangmeng, et al. Weighted nuclear norm minimization with application to image denoising[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2014: 2862-2869.
- [12] NIE Feiping, HUANG Henwei, DING Chenwei. Low-rank matrix recovery via efficient Schatten- p norm minimization[C]//Proceedings of the 26th AAAI Conference on Artificial Intelligence. Toronto, Ontario, Canada: AAAI Press, 2012: 655-661.
- [13] XIE Yuan, GU Shuhang, LIU Yan, et al. Weighted Schatten- p norm minimization for image denoising and background subtraction[J]. IEEE Transactions on Image Processing, 2016, 25(10): 4842-4857.
- [14] BHARDWAJ A, RAMAN S. Robust PCA-based solution to image composition using augmented Lagrange multiplier[J]. Visual Computer, 2016, 32(5): 591-600.
- [15] YUAN Xiaoming, YANG Junfeng. Sparse and low rank matrix decomposition via alternating direction method[J]. Pacific Journal of Optimization, 2009, 9(1): 1-11.
- [16] WANG Yi, JODOIN P M, PORIKLI F, et al. CDnet 2014: an expanded change detection benchmark dataset[C]//Proceedings of Computer Vision and Pattern Recognition Workshops. Washington D. C., USA: IEEE Press, 2014: 393-400.

编辑 刘 冰