

DOI: 10.7652/xjtuxb201606004

低秩矩阵和结构化稀疏分解的视频背景差分方法

刘鑫¹, 张钊强¹, 姚佳文¹, 郭莉莉², 齐春¹
(1. 西安交通大学电子与信息工程学院, 710049, 西安; 2. 云南大学信息学院, 650091, 昆明)

摘要: 针对基于矩阵分解的视频前景检测传统算法中忽视前景元素之间相关性会导致检测结果容易受噪声干扰和运动目标检测不完整等问题,提出了一个低秩矩阵和结构化稀疏分解的视频背景差分算法。该算法充分考虑到视频前景区域的结构化分布特征,利用结构化稀疏范数对前景进行约束;针对矩阵分解方法中参数选择的难题,采用了一种基于运动显著性判定的两步法来实现动态背景去除和正则化参数的自适应选择,即第一步利用低秩和结构化稀疏分解获得运动候选块,第二步对运动候选块进行显著性分析并利用自适应正则化参数的块稀疏分解进行前景检测。实验结果表明:与现有的基于矩阵分解的前景检测方法相比,该算法能够更加适应复杂多变的视频环境,在 I2R 测试库中检测出的前景有较高的精确度和召回率。

关键词: 前景检测;背景差分;矩阵分解;低秩表示;结构化稀疏

中图分类号: TP391 **文献标志码:** A **文章编号:** 0253-987X(2016)06-0023-07

A Background Subtraction Method Based on Decomposition of Low Rank and Sparsity Matrices

LIU Xin¹, ZHANG Zhaoqiang¹, YAO Jiawen¹, GUO Lili², QI Chun¹
(1. School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China;
2. School of Information Science and Engineering, Yunnan University, Kunming 650091, China)

Abstract: A background subtraction method based on decomposition of low-rank and structured sparsity matrices is proposed to solve the problem that detection results are sensitive to noise and incomplete caused by ignoring the relationship between foreground pixels in traditional foreground detection methods based on matrix decomposition. The method takes the structural distribution of the foreground into account, and a structured sparsity constraint is used on the foreground pixels. Moreover, a two-stage framework based on motion saliency is introduced to address the parameter setting issue in dynamic background videos and to tune regularization parameters adaptively. Motion block candidates are obtained by using the low rank and structured sparsity decomposition in the first step. Then, motion saliency analysis is applied to these candidates and the adapt block sparsity decomposition is used to detect the foreground in the second step. Experimental results show that the performance of the proposed method is more adaptive than the existing foreground detection methods based on matrix decomposition in complex videos, and that the proposed approach outperforms the state-of-the-art methods according to the precision and recall results on dataset I2R.

Keywords: foreground detection; background subtraction; matrix decomposition; low rank representation; structured sparsity

视频前景检测是智能视频监控、行为分析^[1]等计算机视觉系统的关键步骤,伴随着近几年来人们对于社会安全问题的日益关注而得到广泛的研究和应用。在各种检测算法中,背景差分被认为是提取前景目标的最有效方法,而背景差分算法核心问题在于如何进行有效的背景建模。作为更高层视觉任务(如目标跟踪和行为识别)的基础环节,背景模型的好坏将直接影响到整个系统的准确性和鲁棒性。

目前国内外关于背景建模的方法大致可以归为以下2类。一类方法为基于像素级的背景模型,包括混合高斯(MoG)模型^[2-3]、贝叶斯模型^[4]、马尔科夫随机场(MRF)模型^[5]、背景字典(Code Book)模型^[6]、像素采样(ViBe)模型^[7]等,但以上基于单像素建模的方法都对背景做了特殊的、固定的假设,并且单像素的独立建模往往忽略了像素间的联系和相关性。综上原因,在复杂多变的视频场景下,基于像素的前景检测算法的表现往往不尽人意。另外一类方法是基于图像级的背景模型,最新的研究热点是基于压缩感知理论的前景检测方法。在压缩感知的理论框架下,Candes等人提出了一种鲁棒主成分分析法(RPCA)^[8-9],假设由视频中的帧组成的矩阵可以分解成2个分别具有低秩和稀疏特性的矩阵,认为

背景矩阵具有低秩特性,前景矩阵具有稀疏特性,从而提出了一个基于主成分追踪(PCP)的鲁棒主成分分析法^[9],用核范数对背景矩阵进行约束,用 l_1 范数对前景矩阵进行约束。与之前所介绍的方法相比,这类视频前景检测算法仅仅需要矩阵分解,同时矩阵分解的机制不需要初始训练,因而可以实现背景估计和前景检测任务的同步进行,而传统的背景提取方法(如混合高斯法等)有着繁多的输入参数。

因此,基于矩阵分解的视频前景检测方法如PCP方法是近年来的一个研究热点。然而,PCP方法有2个可改进之处:①PCP方法没有考虑到前景信号的结构特性;②PCP方法中单一的、固定的尺度参数设置导致模型容易受到动态背景的干扰。针对这2个问题,本文提出了一个两步的框架,如图1所示。首先利用结构化稀疏范数对前景进行建模,提出了一个基于低秩和结构化稀疏分解的前景检测方法,该方法考虑了前景元素的结构信息;然后采用一种时间片段数据运动显著性分析的方法,通过对分解后得到的候选目标进行统计,并计算出相应的平均运动显著性,再根据平均显著性值对每个目标块给予相应的正则参数值;最后采用块稀疏鲁棒主成分分析法进行前景检测。




图1 本文两步框架算法图

1 低秩和结构化稀疏分解前景检测

1.1 PCP方法回顾

PCP法可用公式表示为

$$\|L\|_* + \lambda \|S\|_1, \quad D = L + S \quad (1)$$

式中: $D \in \mathbf{R}^{m \times n}$ 为观测数据,由多个视频帧通过列重排后构成,即 D 矩阵中的每一列对应原始视频的一帧; L 和 S 分别表示进行分解之后得到的背景矩阵和前景矩阵; $\|L\|_*$ 表示矩阵 L 的核范数(nuclear norm),即矩阵 L 的奇异值之和; $\|S\|_1$ 为矩阵的 l_1 范数,即矩阵 S 中元素绝对值之和。

统计信号处理的知识表明^[10],当PCP法利用

l_1 范数约束问题中的稀疏度时,其假设稀疏信号的每一个元素是独立分布的,然而在许多实际问题当中,稀疏信号的分布并不是独立的。例如,在人脸识别领域,实际进行测试的人脸图像中由光照变化造成的阴影、遮挡等不属于人脸部分的异常值在空间上是连续分布的;在视频前景检测中,前景信号可以看成是不属于背景模型的异常值,但前景像素并不是无意义的随机出现在某个位置,它们通常在空间上具有结构化分布的特征。

1.2 基于重叠块的结构化稀疏诱导范数

为了能够将结构特征运用到实际遇到的稀疏信号问题中,文献^[10]提出将变量分为互不相交的组,

然后用所谓的组惩罚项在组的层面上进行稀疏度的约束,即给定任意一组变量 $\mathbf{e} = [e_1, e_2, \dots, e_m] \in \mathbf{R}^m$, 可依据 $\mathbf{e}$ 中每一个元素具有的下标 $\{1, \dots, m\}$ 将 $\mathbf{e}$ 分为由互不相交的组构成的一个集合 G , 其中由若干元素合成的某个组 $g \in G$, 此时组惩罚项可表示为 $\phi(\mathbf{e}) = \sum_{g \in G} \sum_{j \in g} |e_j|^2 = \sum_{g \in G} \|\mathbf{e}_g\|_2$, 这个组惩罚项会使同一组的变量同时调整为零或非零。由于 $\mathbf{e}$ 中元素的稀疏分布尺寸和数量都未知, 在实际应用时要想分成较精确的不重叠局部特征块的难度较大。

为了能够定义更加复杂的结构, Mairal 等人提出了重叠块结构的结构化稀疏诱导范数^[11], 定义式为

$$\Omega(\mathbf{s}) = \sum_{g \in G} \eta_g (\max_{j \in g} |s_j|) = \sum_{g \in G} \eta_g \|\mathbf{s}_g\|_\infty \quad (2)$$

式中: $\mathbf{s}$ 为具有结构化分布特性的稀疏信号; s_j 为 $\mathbf{s}$ 的第 j 个元素; $\|\cdot\|_\infty$ 代表 l_∞ 范数, 指所有元素的最大绝对值; η_g 为每个组的权重, 一般取值为 1; G 为预先定义的组分布的集合, 其中每一个组分布为 g ; $\mathbf{s}_g$ 为组分布为 g 的 $\mathbf{s}$ 的子集。

图 2 给出了本文所采用的基于 3×3 像素大小重叠块的图结构 G 。在一个 8×8 像素大小图片上, 从最左上角开始, 每一个块分别向右和向下移动一个像素, 直至完成整个遍历。在这种设计下, 3×3 像素大小重叠块的组结构对于一个 8×8 像素大小的图片有 36 个组, 即 $G = \{g_1, \dots, g_{36}\}$, 每一个块与其 4 邻域的邻居块会重叠 6 个元素, 而每一个块内元素就构成了一个组 g 。




图 2 3×3 像素大小重叠块图结构

1.3 低秩和结构化稀疏模型

因为结构化稀疏范数允许定义复杂的结构, 所以能够很好地体现出实际问题中稀疏信号的结构化分布特性, 本文利用重叠块作为结构特征对视频中的前景信号进行约束。

对于视频前景检测问题, 式(2)给出的是一帧视频中前景信号的结构化约束, 这相当于对前景矩阵的一系列元素进行定义。通过对式(2)进行扩展, 本文引入如下一个能够对整个前景矩阵进行结构化稀疏

的约束

$$\Omega(\mathbf{S}) = \sum_{j=1}^n \sum_{g \in G} \|\mathbf{s}_{j,g}\|_\infty \quad (3)$$

式中: $\mathbf{S} \in \mathbf{R}^{m \times n}$ 是由具有结构化分布特性的前景信号组成的矩阵, 其第 j 列向量 $\mathbf{s}_j \in \mathbf{R}^m$, 利用式(2)对 $\mathbf{s}_j$ 进行约束。

由于背景矩阵的每一列表示一帧视频的背景信号, 这些不同列的背景信号前后之间具有很大的相关性, 可以分布到一个较低维度的空间上。因此, 用低秩特性对背景矩阵进行约束。同时, 受到文献[12-13]的启发, 对于 $\mathbf{L}$, 本文还采用了 $l_{2,1}$ 约束, 以及对应的正则化参数 κ, v 设置, 从而保证恢复得到的背景矩阵 $\mathbf{L}$ 中对应于前景所在的位置具有零值。最终得到本文模型

$$\min_{\mathbf{L}, \mathbf{S}} \|\mathbf{L}\|_* + \kappa(1-v) \|\mathbf{L}\|_{2,1} + \kappa v \Omega(\mathbf{S})$$

s. t. $\mathbf{D} = \mathbf{L} + \mathbf{S}$ (4)

式中: $\|\mathbf{L}\|_{2,1}$ 为矩阵 $\mathbf{L}$ 的 $l_{2,1}$ 范数, 即 $\|\mathbf{L}\|_{2,1} = \sum_j \|\mathbf{l}_j\|_2$, $\mathbf{l}_j$ 代表矩阵 $\mathbf{L}$ 的第 j 列向量; $\Omega(\mathbf{S})$ 为矩阵 $\mathbf{S}$ 的结构化稀疏范数, 定义如式(3)。

1.4 模型的求解

采用增广拉格朗日乘子法(ALM)求解式(4)的目标函数

$$\begin{aligned} \mathcal{L}(\mathbf{L}, \mathbf{S}, \mathbf{Y}; \mu) = & \|\mathbf{L}\|_* + \kappa(1-v) \|\mathbf{L}\|_{2,1} + \\ & \kappa v \Omega(\mathbf{S}) + \langle \mathbf{Y}, \mathbf{D} - \mathbf{L} - \mathbf{S} \rangle + \frac{\mu}{2} \|\mathbf{D} - \mathbf{L} - \mathbf{S}\|_F^2 \end{aligned} \quad (5)$$

式中: μ 为正惩罚参数; $\mathbf{Y}$ 为拉格朗日乘子向量; $\langle \cdot \rangle$ 代表内积操作; $\|\cdot\|_F$ 表示 Frobenius 范数。

最小化拉格朗日函数式(5)的问题可以转化为下面 3 个子问题

$$\mathbf{L} = \arg \min_{\mathbf{L}} \mathcal{L}(\mathbf{L}, \mathbf{S}, \mathbf{Y}; \mu) \quad (6)$$

$$\mathbf{S} = \arg \min_{\mathbf{S}} \mathcal{L}(\mathbf{L}, \mathbf{S}, \mathbf{Y}; \mu) \quad (7)$$

$$\mathbf{Y} = \mathbf{Y} + \mu(\mathbf{D} - \mathbf{L} - \mathbf{S}) \quad (8)$$

当 $\mathbf{S}$ 和 $\mathbf{Y}$ 固定时, 求解 $\mathbf{L}$ 的子问题式(6)可以写为

$$\begin{aligned} \min_{\mathbf{L}} \frac{\mu}{2} \|\mathbf{D} - \mathbf{L} - \mathbf{S}\|_F^2 + \langle \mathbf{Y}, \mathbf{D} - \mathbf{L} - \mathbf{S} \rangle + \\ \|\mathbf{L}\|_* + \kappa(1-v) \|\mathbf{L}\|_{2,1} \end{aligned} \quad (9)$$

通过加入一个无关项 $\|\mathbf{Y}\|_F^2/2\mu$, 可以将问题式(9)表示为下面等价的优化问题

$$\begin{aligned} \min_{\mathbf{L}} \frac{\mu}{2} \|(\mathbf{D} - \mathbf{S} + \mu^{-1}\mathbf{Y}) - \mathbf{L}\|_F^2 + \\ \|\mathbf{L}\|_* + \kappa(1-v) \|\mathbf{L}\|_{2,1} \end{aligned} \quad (10)$$

本文采用了文献[13]中的 Douglas/Peaceman-

Rachford(DR)迭代算法进行求解。DR 迭代算法在第 j 次迭代中分别更新 $\mathbf{L}^{(j+1/2)}$ 和 $\mathbf{L}^{(j+1)}$ 两个值,然后进行循环迭代,直至收敛得到最优的解 $\mathbf{L}$ 。

采用类似的方法,将求解 $\mathbf{S}$ 的子问题式(7)化简为

$$\min_{\mathbf{S}} \frac{\mu}{2} \|(\mathbf{D} - \mathbf{L} + \mu^{-1} \mathbf{Y}) - \mathbf{S}\|_F^2 + \kappa \psi(\mathbf{S}) \quad (11)$$

对于问题式(11),本文采用一个二次最小割方法^[12]去求解。

当 $\mathbf{L}$ 和 $\mathbf{S}$ 都求解完毕后,最后更新拉格朗日乘子 $\mathbf{Y}$,即式(8)。

利用 ALM 方法求解本文低秩和结构化稀疏分解问题式(4)的计算流程如下(具体的参数设置请参考文献[12-13]):

- (1) 输入矩阵 $\mathbf{D}$, 参数初始化;
- (2) while not converge do;
- (3) // 求解 $\mathbf{L}_{k+1} = \arg \min_{\mathbf{L}} \mathcal{L}(\mathbf{L}, \mathbf{S}_k, \mathbf{Y}_k; \mu)$;
- (4) $\mathbf{G}_L = \mathbf{D} - \mathbf{S}_k + \mu_k^{-1} \mathbf{Y}_k$;
- (5) $j \leftarrow 0, \mathbf{L}_{k+1}^0 \leftarrow \mathbf{G}_L$;
- (6) while not converge do;
- (7) $\mathbf{L}_{k+1}^{(j+1/2)} = \mathbf{U} \mathbf{S}_{\beta}(\boldsymbol{\Sigma}) \mathbf{V}^T$, 其中 $\mathbf{L}_{k+1}^{(j)} = \mathbf{U} \boldsymbol{\Sigma} \mathbf{V}^T$ 为 $\mathbf{L}_{k+1}^{(j)}$ 的 SVD 分解;

- (8) $\Delta = \alpha \left(\mathbf{T}_{\frac{\beta_k(1-\nu)}{1+\beta_k}} \left(\frac{2\mathbf{L}_{k+1}^{(j+1/2)} - \mathbf{L}_{k+1}^{(j)} + \beta \mu_k \mathbf{G}_L}{1 + \beta \mu_k} \right) - \mathbf{L}_{k+1}^{(j+1/2)} \right)$;
- (9) $\mathbf{L}_{k+1}^{(j+1)} = \mathbf{L}_{k+1}^{(j)} + \Delta$;
- (10) $j \leftarrow j + 1$;
- (11) end while;
- (12) $\mathbf{L}_{k+1} = \mathbf{L}_{k+1}^{(j+1/2)}$;
- (13) // 求解 $\mathbf{S}_{k+1} = \arg \min_{\mathbf{S}} \mathcal{L}(\mathbf{L}_{k+1}, \mathbf{S}, \mathbf{Y}_k; \mu)$;
- (14) $\mathbf{G}_S = \mathbf{D} - \mathbf{L}_{k+1} + \mu_k^{-1} \mathbf{Y}_k$;
- (15) $\mathbf{S}_{k+1} = \text{prox}_{\mathbf{G}}(\mathbf{G}_S)$;
- (16) $\mathbf{Y}_{k+1} = \mathbf{Y}_k + \mu_k (\mathbf{D} - \mathbf{L}_{k+1} - \mathbf{S}_{k+1})$;
- (17) $\mu_{k+1} = \rho \mu_k; k \leftarrow k + 1$;
- (18) end while.

图3给出了利用本文算法在光照突变的情况下进行前景检测的结果,并且与现有的基于矩阵分解的检测方法 DECOLOR 法^[14]、LBD 法^[12]和 PCP 法^[9]进行了对比。从图中可以看出,由于采用了结构化特征的约束,采用本文法得到的前景检测结果更加完整,并且能够及时响应光线的变化,得到了更加准确的背景估计。




图3 本文低秩和结构化稀疏分解方法与 DECOLOR、LBD 及 PCP 方法结果比较

2 自适应正则参数设置的块稀疏分解

利用上述低秩和结构化稀疏分解,可以得到运动候选块,但是由于矩阵分解的方法存在参数选择的难题,这些运动候选块既包含真正前景,也包含背景部分的运动。本文利用运动显著性分析技术来判断经过分解后得到的运动候选块中哪些属于背景运动,哪些属于真正的前景运动。

在矩阵分解方法的模型中,很难选择单一的参数去适应所有场景。简单来讲,在式(1)中,因为参数 λ 控制着矩阵分解后背景和前景的比例,对于前景检测任务,希望 λ 值小一点从而使得得到完整的前景目标;对于背景估计任务,同样也希望 λ 值小一点,从而使得恢复的背景中不会具有前景的残影。考虑到得到完整目标的重要性,在以往的算法中往往采用了一个较小的、固定的 λ 值,但是这种全局

的、统一的参数设置使得模型很难去除复杂多变的背景运动的干扰。

2.1 运动显著性分析

事实上,视频中的运动目标有着如下的3个基本观测结果^[15]:①前景区域的尺寸通常小于背景区域;②背景运动的程度通常小于前景运动;③即使视频中存在动态背景,背景通常具有更加统一的特征模式。因此,本文首先对视频的时间域切片^[16]进行分析,采用文献[16]的算法进行运动显著性检测,然后将运动显著性在图像块的层面进行统计,即计算运动候选块(矩阵分解后的前景部分)的平均运动显

著值。如图4中候选块 B 是由视频场景中的光照变化(阴影)产生的,低秩和结构化稀疏矩阵分解算法也会检测到该变化,但是由于这个变化在整个时间域上变化并不显著,如果再以图像块的方式进一步统计,就会得到一个很低的显著性平均值 $\overline{M}_B$ 。相反,对于真正的前景块 A (摩托车和人),因为其内部的各个像素点具有很高的运动显著性,所以该图像块的平均运动显著性 $\overline{M}_A$ 值比较高。文献[16]假设运动显著性值服从高斯分布 (μ, σ) 。在此假设的基础上,本文定义一个阈值 $h_t = \mu + \sigma$,自适应地过滤掉运动显著性值低于该阈值的候选块。




图4 利用运动显著图进行运动分析

2.2 块稀疏分解

经过运动显著性分析之后,平均运动显著性值较低的(背景运动)块会被滤掉。对于其他候选块,已知块的大小和位置以及运动显著性参数,在第二步中采用块稀疏鲁棒主成分分析方法^[15](Block-sparse RPCA)进行最终的前景检测

$$\min_{L, S} \|L\|_* + \sum_i \lambda_i \|p_i(S)\|_F, \quad D = L + S \quad (12)$$

式中: D 为观测数据; L 为分解得到的低秩部分; S 为分解得到的块稀疏部分; $\|\cdot\|_F$ 为矩阵的Frobenius范数; p_i 代表一个操作函数,用来将 S 的每一列中表示第 i 块的元素提取出来,用作下一步的处理。根据文献[15,17],第 i 块的正则化参数计算如下

$$\lambda_i = \frac{1}{10(\max(m, n))^{1/2}} \frac{\overline{M}_{\min}}{\overline{M}_i} \quad (13)$$

式中:最后一项用来归一化平均运动显著性; $\overline{M}_{\min}$ 表示所有候选块中的最低显著性值; $\overline{M}_i$ 表示第 i 个运动候选块所具有的平均运动显著值。对于块稀疏RPCA问题的求解,仍可以采用ALM方法,具体求解步骤参考文献[15,17]。

由于本文提出的两步框架是在图像块的层面对视频进行处理,并且针对背景变化和前景运动来设置不同的正则参数值,因此能够在得到准确的背景估计的同时得到完整的前景检测结果(见图5b和

图5e),而PCP方法采用单一的参数设置,如图5c、图5f所示,虽然 λ 较小时能得到较完整的前景目标(人),但是同时也误检出运动的背景(海浪);如果设置较大的 λ ,那么运动目标被融入背景中,动态背景(海浪)也并没有被完全过滤掉,如图5d及图5g所示。




图5 本文方法与PCP方法前背景分离结果对比

3 实验结果及分析

为了验证本文算法的有效性,在实验部分,与现有的 4 种方法进行了对比,包含 3 个目前最新的基于矩阵分解的方法(DECOLOR^[14], LBD^[12] 和 PCP^[9])和一个基于单像素建模的经典算法 ViBe^[7]。

本文采用 I2R 测试视频数据库^[4]进行实验,这个测试库共包含 9 段视频,主要包括了动态背景(树枝、水面、窗帘运动、喷泉、电梯等)、光照渐变及突变(开关灯)、阴影等测试场景。首先给出针对复杂动

态背景的定性对比实验的结果图。从图 6~8 可以看出,针对包含复杂动态背景的视频 Campus(CAM), Fountain(FT), Escalator(ES), 本文方法能有效地去除动态背景的干扰,同时也能准确地检测出前景目标。DECOLOR 方法往往得出过于光滑的检测效果,产生了大量的误检,其他方法则不能有效地去除动态背景的干扰,本文方法有效地处理了这些视频,比其他算法得到了更好的检测结果。

定量实验中,采用以下 3 个指标来评价检测结果

$$r = \frac{T}{T + F_N}$$

(14)




图 6 I2R 综合测试视频数据库 CAM 视频的前景检测结果比较




图 7 I2R 综合测试视频数据库 ES 视频的前景检测结果比较



图 8 I2R 综合测试视频数据库 FT 视频的前景检测结果比较

$$p = \frac{T}{T + F_p}$$

(15)

$$F = \frac{2rp}{r + p}$$

(16)

式中: T 为检测结果当中属于正确分割的前景像素个数; F_N 为结果当中没有检测出来的部分,即漏检的前景像素的数目; F_p 为结果当中错误认为前景的部分,即误检为前景像素的数目; F 为综合测量指标,是综合考虑召回率(r)和精确率(p)后可代表方法性能的指标,若某个方法的 F 值越高,则表明该方法对于该视频的前景检测结果越好。

表 1 给出了定量实验下的 F 测量指标,由表 1 可以看出,本文方法在 6 段视频下的 F 最高,在其余 3 段视频中排名第 2。综合来看,本文方法在 I2R 综合测试视频数据库上有最高的平均 F 测量值。

表 1 I2R 综合测试视频数据库各个方法的 F 指标

视频	F				
	本文方法	DECOLOR	LBD	PCP	ViBe
CAM	75.04	73.29	28.75	40.69	36.17
BO	58.41	56.86	56.47	56.78	63.30
CU	83.13	81.58	82.22	81.28	82.49
ES	70.79	75.46	50.90	63.54	57.04
FT	84.98	82.76	59.25	63.74	55.80
WS	89.13	79.65	81.75	39.76	86.02
HA	59.15	53.20	48.75	50.26	61.16
LO	72.80	56.52	66.26	62.18	26.41
SH	74.02	68.06	65.49	66.78	68.54
平均	73.65	69.71	59.98	58.33	59.66

注:黑体数据为同一条件下的最高值。

4 结 论

本文充分考虑了视频前景的结构化分布特性以及背景图像之间的相关性,提出了一个基于低秩和结构化稀疏分解的视频前景检测方法,实现了背景矩阵估计和前景矩阵分割的同步进行。此外,针对目前基于矩阵分解方法中存在参数选择的尺度问题,利用一个基于运动显著性的两步框架来实现参数的自适应选择。实验结果表明,本文提出的两步框架可以处理动态背景视频下的正则化参数选择问题,在标准测试数据库上进行视频场景的对比实验中取得了更好的检测效果。目前,本文方法的讨论只局限于固定相机下的视频处理,未来将考虑处理其他运动特征从而可以将工作扩展到移动相机下的视频前景检测。

参考文献:

- [1] 王伟嘉,刘辉,沙莉,等. 滞留与偷窃物体实时检测与分类算法 [J]. 计算机应用, 2007, 27(10): 2591-2594.
WANG Weijia, LIU Hui, SHA Li, et al. Real time detection and classification algorithm for abandoned and stolen objects [J]. Computer Applications, 2007, 27(10): 2591-2594.
- [2] STAUFFER C, GRIMSON W E L. Adaptive background mixture models for real-time tracking [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 1999: 246-252.
- [3] 刘鑫,刘辉,强振平,等. 混合高斯模型和帧间差分相融合的自适应背景模型 [J]. 中国图象图形学报, 2008, 13(4): 729-734.
LIU Xin, LIU Hui, QIANG Zhengping, et al. Adaptive background modeling based on mixture Gaussian model and frame subtraction [J]. Journal of Image and Graphic, 2008, 13(4): 729-734.
- [4] LI L Y, HUANG W M, GU I H, et al. Statistical modeling of complex backgrounds for foreground object detection [J]. IEEE Transactions on Image Processing, 2004, 13(11): 1459-1472.
- [5] SHEIKH Y, SHAH M. Bayesian modeling of dynamic scenes for object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(11): 1778-1792.
- [6] KIM K, CHALIDABHONGSE T H, HARWOOD D, et al. Realtime foreground-background segmentation

- using codebook model [J]. Real-Time Image, 2005, 11(3): 172-185.
- [7] BARNICH O, VAN DROOGENBROECK M. ViBe: a universal background subtraction algorithm for video sequences [J]. IEEE Transactions on Image Processing, 2011, 20(6): 1709-1724.
- [8] CANDES E J, LI X, MA Y, et al. Robust principal component analysis? [J]. Journal of the ACM, 2011, 58(3): 11-47.
- [9] WRIGHT J, YANG A Y, GANESH A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
- [10] TIBSHIRANI R. Regression shrinkage and selection via the lasso [J]. Journal of the Royal Statistical Society: Series B Methodological, 1996, 58(1): 267-288.
- [11] MAIRAL J, JENATTON R, BACH F R, et al. Network Flow Algorithms for Structured Sparsity [C] // Proceedings of Neural Information Processing Systems. Vancouver, Canada: NIPS, 2010: 1558-1566.
- [12] GUYON C, BOUWMANS T, ZAHZAH E H. Foreground detection based on low-rank and block-sparse matrix decomposition [C] // Proceedings of the IEEE International Conference on Image Processing. Piscataway, NJ, USA: IEEE, 2012: 1225-1228.
- [13] TANG G, NEHORAI A. Robust principal component analysis based on low-rank and block-sparse matrix decomposition [C] // Proceedings of the Annual Conference on Information Sciences and Systems. Piscataway, NJ, USA: IEEE, 2011: 1-5.
- [14] ZHOU X W, YANG C, YU W. Moving object detection by detecting contiguous outliers in the low-rank representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(3): 597-610.
- [15] GAO Z, CEONG L F, SHAN M. Block-sparse RPCA for consistent foreground detection [C] // Proceedings of the European Conference on Computer Vision. Heidelberg, Germany: Springer, 2012: 690-703.
- [16] CUI X Y, LIU Q S, ZHANG S T, et al. Temporal Spectral Residual for fast salient motion detection [J]. Neurocomputing, 2012, 86: 24-32.
- [17] LIN Z, CHEN M, MA Y. The augmented Lagrange multiplier method for exact recovery of corrupted low-rank matrices [EB/OL]. (2013-10-18)[2015-11-20]. <http://arxiv.org/pdf/1009.5055v3.pdf>.

(编辑 刘杨)