

复杂动态背景下基于群稀疏的运动目标检测方法

王洪雁^{1,2}, 张海坤², 罗宇华³, 汪祖民²

(1. 浙江理工大学信息学院, 浙江杭州 310018; 2. 大连大学信息工程学院, 辽宁大连 116622;
3. 上海精密计量测试研究所, 上海 201109)

摘要: 为提高复杂动态背景下运动目标检测精度, 基于低秩及稀疏分解理论, 本文提出一种基于群稀疏的运动目标检测方法. 所提方法将观测视频分解为低秩静态背景, 群稀疏前景及动态背景三部分. 所提方法首先使用伽马范数近乎无偏近似矩阵秩函数, 以解决核范数过度惩罚较大奇异值导致所得最小化问题无法获得最优解进而降低检测性能的问题; 其次, 为利用前景目标边界先验信息以提升运动目标检测性能, 每一帧使用过分割算法生成同性区域以定义群稀疏范数并用于约束前景矩阵; 再次, 为避免运动目标同时出现在稀疏前景和动态背景中, 引入非相干项以提升二者可分性; 最后, 本文利用交替方向乘子方法 (Alternating Direction Method of Multipliers, ADMM) 求解所得非凸目标函数. 实验结果表明, 与现有主流运动目标检测算法相比, 复杂动态背景下本文所提方法可较好抑制动态背景从而显著提高复杂运动背景下运动目标检测精度.

关键词: 运动目标检测; 动态背景; 低秩; 群稀疏; 超像素

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112(2021)12-2330-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20200816

Moving Object Detection Method Based on Group Sparseness Under Complex Dynamic Background

WANG Hong-yan^{1,2}, ZHANG Hai-kun², LUO Yu-hua³, WANG Zu-min²

(1. School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou, Zhejiang 310018, China;
2. College of Information Engineering, Dalian University, Dalian, Liaoning 116622, China;
3. Shanghai Precision Metrology & Test Research Institute, Shanghai 201109, China)

Abstract: To improve the accuracy of moving object detection under complex dynamic background, based on the theory of low-rank and sparse decomposition, a group sparse based moving object detection method is developed. The proposed method decomposes the observed video into a low-rank static background, a group sparse foreground and a dynamic background. Regarding the problem that the nuclear norm over-penalizing large singular values leads to the optimal solution of the obtained minimization problem cannot be obtained and then the detection performance is decreased, the gamma norm is introduced to acquire almost unbiased approximation of rank function. In order to utilize the object boundary prior to enhance the moving target detection performance, each frame is over-segmented into homogeneous regions which are taken to define the group sparse norm to constrain the foreground matrix. Moreover, to prevent the moving object from appearing in the sparse foreground and dynamic background simultaneously, the incoherence term is introduced to enhance the separability of them. Finally, the obtained non-convex objective function can be solved using the alternating direction multiplier method (ADMM). The experimental results show that, compared with the state-of-the-art moving target detection algorithms, the developed method can suppress the dynamic background considerably and then improve the accuracy of moving object detection significantly under complex dynamic background.

Key words: moving object detection; dynamic background; low-rank; group sparse; superpixel

1 引言

作为计算机视觉领域研究热点,动目标检测在智能家居,交通监控及安防等领域发挥着重要作用^[1].近年来,众多动目标检测算法相继被提出,极大提升了此领域理论应用水准.然而,由于现实场景中不可避免存在相机抖动、阴影及动态背景等复杂因素,高精度且鲁棒的运动目标检测仍较为困难^[2].

背景减除(Background Subtraction, BS)作为传统动目标检测算法,其假设背景静止并通过构建背景模板而后比较当前帧与模板以检测目标^[3].众多背景减除算法中,鲁棒主分量分析(Robust Principal Component Analysis, RPCA)^[4]将视频视为前背景的叠加,并对二者分别使用低秩及稀疏约束,通过增广拉格朗日乘子(Augmented Lagrange Multipliers, ALM)法^[5]求解该模型以实现动目标检测.但由于RPCA未考虑观测噪声影响,因而动态背景下检测精度显著下降.针对此问题,文献[6]提出“去分解”(Go Decomposition, GoDec)模型,基于RPCA引入噪声项以增强模型噪声鲁棒性,然而观测数据缺失条件下 L_2 损失项将导致检测性能降低.据此,文献[7]提出概率鲁棒矩阵分解(Probabilistic Robust Matrix Factorization, PRMF)模型,利用 L_1 损失项和 L_2 正则项提升大尺度矩阵分解鲁棒性从而提高检测精度.然而,由于未考虑前景空间分布特性从而导致虚警率较高.基于此,文献[8]提出低秩表示检测连续异常值(DEtecting Contiguous Outliers in the LOW-rank Representation, DECOLOR)模型,利用目标通常呈现弱聚类特性先验知识以降低虚警率,然而由于使用固定分布建模噪声,强运动背景下检测精度下降明显.针对此问题,文献[9]提出混合高斯-RPCA(Mixture of Gaussians-RPCA, MoG-RPCA)模型,基于MoG建模噪声以适应复杂场景,然而存在超参数较多,建模复杂等问题.

针对上述问题,本文提出复杂动态背景下基于群稀疏的动目标检测方法.所提方法将视频分解为低秩静态背景,群稀疏前景和动态背景三部分.与现有基于群稀疏及核范数约束低秩静态背景的检测方法^[10,11]不同的是,所提方法首先利用可近乎无偏估计秩函数的 γ 范数约束低秩静态背景,以解决核范数过度惩罚较大奇异值致使所得问题无法获得最优解从而导致检测性能显著下降的问题;其次利用简单线性迭代聚类(Simple Linear Iterative Clustering, SLIC)^[12]算法将视频过分割为超像素以定义群稀疏范数并约束稀疏前景;同时为增强前背景可分离性,引入非相干项以避免动目标同时出现于群稀疏前景和动态背景;最后基于交替方向乘子方法(Alternating Direction Method of Multipliers, ADMM)求解所得非凸模型.实验表明,与主流动目标检测算法相比,所提方法具有较高检测精度及鲁棒性.

2 所提运动目标检测方法

本节首先给出 γ 范数定义,其次使用SLIC算法过分割视频序列以形成同性区域并定义群稀疏范数以约束稀疏前景矩阵,而后引入非相干项约束,并在此基础上构建基于群稀疏的运动目标检测模型.

2.1 γ 范数

传统RPCA模型利用核范数约束低秩背景矩阵,然由于其过度惩罚较大奇异值导致有偏估计从而使得最小化问题无法获得最优解^[13],而增强极大极小凹(Min-max Concave Plus, MCP)函数可近乎无偏估计秩函数,因而作为MCP矩阵扩展形式的 γ 范数在秩最小化问题中可获得较好近似解^[14].给定向量 $\beta = (\beta_1 \beta_2 \cdots \beta_p)^T \in \mathbb{R}^p$, $(\cdot)^T$ 表示转置, $\lambda > 0, \gamma > 1$,MCP函数可定义为 $M_{\lambda,\gamma}(\beta) = \sum_{i=1}^p \Omega_{\lambda,\gamma}(\beta_i)$,其中

$$\Omega_{\lambda,\gamma}(t) = \lambda \int_0^t \left[1 - \frac{x}{\lambda\gamma} \right]_+ dx = \begin{cases} \frac{\lambda^2 \gamma}{2}, & |t| \geq \lambda\gamma \\ \lambda |t| - \frac{t^2}{2\gamma}, & \text{其他} \end{cases} \quad (1)$$

$(z)_+ = \max\{z, 0\}$.同理,给定矩阵 $A = [A_{i,j}] \in \mathbb{R}^{m \times n}$, $A_{i,j}$ 为 A 的第 (i,j) 个元素,其MCP范数可定义为 $M_{\lambda,\gamma}(A) = \sum_{i,j} \Omega_{\lambda,\gamma}(A_{i,j})$.

设 A 奇异值分解为 $A = U_A \Sigma_A V_A^T$,其中, $U_A = [u_1 u_2 \cdots u_n]$, $V_A = [v_1 v_2 \cdots v_n]$ 分别为左右奇异矩阵, $\Sigma_A = \text{diag}(\sigma_1 \sigma_2 \cdots \sigma_n)$ 为对角阵,且 $\sigma_1 \geq \cdots \geq \sigma_n$,令 $\sigma(A) = (\sigma_1(A) \cdots \sigma_r(A))^T$, $\sigma_i(A)$ 为 A 的第 i 个奇异值, $r = \min\{m, n\}$.令 $\Omega_\gamma(t) = \Omega_{1,\gamma}(t)$, $M_\gamma(A) = M_{1,\gamma}(A)$,则 A 的 γ 范数可定义为:

$$\|A\|_\gamma = \sum_{i=1}^r \int_0^{\sigma_i(A)} (1 - u/\gamma)_+ du = \sum_{i=1}^r \Omega_{1,\gamma}(\sigma_i(A)) = M_\gamma(\sigma(A)) \quad (2)$$

2.2 基于超像素分割的群稀疏范数

由于RPCA及其部分衍生模型基于 L_1 范数识别目标像素,其无法消除随机背景扰动所致非结构性稀疏误差,因而复杂动态背景下检测结果较差^[15].此外,动目标并非随机出现,其空间分布具有相关性和连续性,因此对前景目标施加空间约束可提高目标检测精度.为较好利用目标边界先验信息,本文基于SLIC算法过分割图像以生成若干超像素,所得超像素可视为同性区域^[10],其可为后续检测提供丰富边界信息.相较于Normalize Cut^[16]和TurboPixels^[17]等分割算法,SLIC简单快速且所获取边界信息更完整^[18].由于SLIC并未施加超像素间连续性约束,若某区域像素显著不同时,则该区域被分割为多个超像素,因此,同一超像素内像素倾

向属于相同类别. 定义 g_i 为第 i 个超像素内所有像素坐标集合, 则整个视频的同性区域可表示为:

$$G = \{g_i | 1 \leq i \leq J\} \quad (3)$$

其中, J 为生成同性区域总数, 同性区域集合 G 满足 $g_i \cap g_j = \emptyset, \forall i \neq j$ 且 $\bigcup_{i=1}^J g_i$ 可覆盖视频所有像素. 基于 SLIC 过分割图像所得结果如图 1 所示. 由图 1 可知, 所得同性区域可有效定位目标边界, 各同性区域内像素可被识别为移动前景或背景. 因而, 本文使用集合 G 定义群稀疏范数^[19]以分离运动目标.




图1 SLIC算法过分割结果

令 E 为群稀疏前景或背景, 基于上述所得同性区域集合, 群稀疏范数可表示为:

$$\|E\|_{\text{Group}} = \text{card} \left\{ i \mid \|E(g_i)\|_2 \neq 0, g_i \in G \right\} \quad (4)$$

其中, $\text{card}\{\cdot\}$ 为集合非零元素个数, $\|\cdot\|_2$ 为 L_2 范数, $E(g_i)$ 为 g_i 对应 E 像素值排列所形成向量, 该范数确保仅少数同性区域 $E(g_i)$ 非零.

2.3 非相干性约束

为增强模型的鲁棒性, 本文将视频 D 分解为低秩静态背景 A , 群稀疏前景 E_1 及动态背景 E_2 , 即

$$D = A + E_1 + E_2 \quad (5)$$

为避免动目标同时出现于 E_1, E_2 , 引入非相干项 $\sum_{r=1}^N E_{1r}^T E_{2r}$ 以增强 E_1, E_2 的可分离性, 其中 E_{1r}, E_{2r} 分别为 E_1, E_2 的第 r 列. 基于以上所述, 通过 γ 范数近乎无偏估计秩函数以约束低秩静态背景 A , 利用式(4)所定义群稀疏范数约束前景 E_1 并引入非相干项以增强 E_1, E_2 可分性, 可得如下动目标检测模型:

$$\min \|A\|_{\gamma} + \lambda_1 \|E_1\|_{\text{Group}} + \lambda_2 \|E_2\|_{\text{F}}^2 + \lambda_3 \sum_{r=1}^N E_{1r}^T E_{2r} \quad (6)$$

$$\text{s.t. } D = A + E_1 + E_2$$

其中, $D = [I_1 I_2 \dots I_N] \in \mathbb{R}^{M \times N}$ 为观测矩阵, I_i 为单帧图

像, λ_1, λ_2 和 λ_3 为正则化因子. $\|A\|_{\gamma}$ 为背景的 γ 范数.

$\|E_2\|_{\text{F}}^2$ 为 E_2 的 Frobenius 范数, 选择此范数的理由如下: 背景动态变化通常非稀疏且非结构化, 因而更适合基于 Frobenius 范数表达.

3 所提运动目标检测模型求解

明显地, 模型式(6)为多变量非凸问题, 无法直接利用传统优化方法求解. ADMM 可将多变量问题转化为多个易于求解单变量问题, 而后交替求解之^[20]. 基于此, 为兼顾计算复杂度及有效性, 本节基于 ADMM 求解该非凸问题, 算法思路如下: 首先引入额外 Frobenius 范数项 $\frac{\mu}{2} \|D - A - E_1 - E_2\|_{\text{F}}^2$ 将等式约束多变量非凸动目标检测模型转化为无约束优化问题, 而后固定无关变量交替求解低秩静态背景 A 、群稀疏前景 E_1 、动态背景 E_2 并更新拉格朗日乘子 Y , 直至满足迭代终止条件. 具体步骤如下所示.

问题式(6)的增广拉格朗日函数可表述为:

$$\begin{aligned} L(A, E_1, E_2, Y, \mu) = & \|A\|_{\gamma} + \lambda_1 \|E_1\|_{\text{Group}} + \lambda_2 \|E_2\|_{\text{F}}^2 \\ & + \lambda_3 \sum_{r=1}^N E_{1r}^T E_{2r} + \langle Y, D - A - E_1 - E_2 \rangle \\ & + \frac{\mu}{2} \|D - A - E_1 - E_2\|_{\text{F}}^2 \end{aligned} \quad (7)$$

其中, Y 为拉格朗日乘子, $\mu > 0$ 为惩罚参数. 设当前迭代次数为 k , 则各子问题求解过程如下所示.

步骤 1 估计低秩静态背景 A^{k+1} : 固定 E_1 和 E_2 , 求解问题式(8)以更新 A

$$\begin{aligned} A^{k+1} = \arg \min_A & \|A\|_{\gamma} + \langle Y^k, D - A^k - E_1^k - E_2^k \rangle + \\ & \frac{\mu_k}{2} \|D - A^k - E_1^k - E_2^k\|_{\text{F}}^2 \end{aligned} \quad (8)$$

舍弃与优化变量无关项, 上式可简化为:

$$A^{k+1} = \arg \min_A \frac{1}{\mu_k} \|A\|_{\gamma} + \frac{1}{2} \left\| A - \left(D - E_1^k - E_2^k + \frac{Y^k}{\mu_k} \right) \right\|_{\text{F}}^2 \quad (9)$$

由于 $\|A\|_{\gamma}$ 关于 $\sigma(A)$ 非凸, 因而每次迭代可基于 $\|A\|_{\gamma}$ 在 $\sigma(A^{\text{old}})$ 的局部线性逼近 (Locally Linear Approximation, LLA) 以近似求解, 其中 A^{old} 为上次迭代值^[14]. 基于此, 上述优化问题可等价于:

$$\begin{aligned} A^{k+1} = \arg \min_A & \frac{1}{\mu_k} Q_{\gamma}(\sigma(A) | \sigma(A^{\text{old}})) \\ & + \frac{1}{2} \left\| A - \left(D - E_1^k - E_2^k + \frac{Y^k}{\mu_k} \right) \right\|_{\text{F}}^2 \end{aligned} \quad (10)$$

其中,

$$Q_\gamma(A|A^{\text{old}}) = M_\gamma(A^{\text{old}}) + \sum_{i,j} \left(1 - |A_{ij}^{\text{old}}|/\gamma\right)_+ \left(|A_{ij}| - |A_{ij}^{\text{old}}|\right)$$

为给定 A^{old} 时的 LLA.

对任意 $\tau \geq 0, \gamma > 1, X = U_X \Sigma_X V_X^T$ 为 X 的奇异值分解, 令 $A = (I - \Sigma_X^{\text{old}}/\gamma)$, I 为单位矩阵, 则问题式(11)的最优解如式(12)所示:

$$\min_X \frac{1}{2} \|X - Y\|_F^2 + \tau Q_\gamma(\sigma(X) | \sigma(X^{\text{old}})) \quad (11)$$

$$\Theta_{\tau, A}(Y) = U_Y D_{\tau, A}(\Sigma_Y) V_Y^T \quad (12)$$

$\Theta_{\tau, A}(Y), [D_{\tau, A}(A)]_{ij} = \text{sgn}(A_{ij}) (|A_{ij}| - \tau \Lambda_{ij})_+$ 分别为广义奇异值收缩及收缩算子^[21], $\text{sgn}(\cdot)$ 为符号函数.

同理, 对比优化问题式(11), 问题式(10)的最优解为:

$$A^{k+1} = \arg \min_A \Theta_{\frac{1}{\mu_k}, A} \left(D - E_1^k - E_2^k + \frac{Y^k}{\mu_k} \right) \quad (13)$$

步骤2 估计群稀疏前景 E_1^{k+1} : 固定 A, E_2 , 求解如下优化问题以更新 E_1 .

$$E_1^{k+1} = \arg \min_{E_1} \lambda_1 \|E_1\|_{\text{Group}} + \lambda_3 \sum_{r=1}^N (E_{1r})^T E_{2r}^k + \langle Y^k, D - A^{k+1} - E_1^k - E_2^k \rangle + \frac{\mu_k}{2} \|D - A^{k+1} - E_1^k - E_2^k\|_F^2 \quad (14)$$

经过简单矩阵运算, 问题式(14)可简化为:

$$E_1^{k+1} = \arg \min_{E_1} \frac{\lambda_1}{\mu_k} \|E_1\|_{\text{Group}} + \frac{1}{2} \left\| E_1 - \left(D - A^{k+1} - \left(\frac{\gamma}{\mu_k} + 1 \right) E_2^k + \frac{Y^k}{\mu_k} \right) \right\|_F^2 \quad (15)$$

上述问题可通过群硬阈值化算子求解^[22]. 给定矩阵 M , $[M]_{ij}$ 为 M 第 (i, j) 个元素, 第 i 列表示为 $[M]_{:,i}$, 则矩阵的 $L_0, L_{2,0}, L_1, L_{2,1}$ 范数分别定义为: $\|M\|_0 = \{(i, j): [M]_{ij} \neq 0\}$, $\|M\|_{2,0} = \left\{ i: \|[M]_{:,i}\|_2 \neq 0 \right\}$, $\|M\|_1 = \sum_{i,j} |[M]_{ij}|$, $\|M\|_{2,1} = \sum_i \|[M]_{:,i}\|_2$. 由文献[22]可知, L_0 和 $L_{2,0}$ 范数可分别松弛为 $L_1, L_{2,1}$ 范数, 又由文献[22]中引理 4.1 知, 给定矩阵 Q , 若下式最优解为 W^*

$$\min_W \alpha \|W\|_{2,1} + \frac{1}{2} \|W - Q\|_F^2 \quad (16)$$

则 W^* 的第 i 列可表述如下:

$$[W^*]_{:,i} = \begin{cases} \frac{\|[Q]_{:,i}\|_2 - \alpha}{\|[Q]_{:,i}\|_2} [Q]_{:,i}, & \|[Q]_{:,i}\|_2 > \alpha \\ 0, & \text{其他} \end{cases} \quad (17)$$

令 $T = D - A^{k+1} - (\gamma/\mu_k + 1)E_2^k + Y^k/\mu_k$, 则问题式(15)可重新表示为:

$$E_1^{k+1} = \arg \min_{E_1} \frac{\lambda_1}{\mu_k} \|E_1\|_{\text{Group}} + \frac{1}{2} \|E_1 - T\|_F^2 \quad (18)$$

由此, 问题式(18)的最优解可表示为:

$$E_1^{k+1} = \mathfrak{S}_{\frac{\lambda_1}{\mu_k}} [T(g_i)] \quad (19)$$

其中, $T(g_i)$ 表示坐标集合 g_i 对应 T 中像素值重排列形成的向量, \mathfrak{S} 为阈值收缩算子, 其定义如下:

$$\tilde{T}(g_i) = \begin{cases} T(g_i), & \|T(g_i)\|_2 > \frac{\lambda_1}{\mu_k} \\ 0, & \text{其他} \end{cases} \quad (20)$$

步骤3 估计动态背景 E_2^{k+1} : 固定 A, E_1 , 求解问题式(21)以更新 E_2 .

$$E_2^{k+1} = \arg \min_{E_2} \lambda_3 \sum_{r=1}^N (E_{1r}^{k+1})^T E_{2r} + \lambda_2 \|E_2\|_F^2 + \frac{\mu_k}{2} \left\| E_2 - \left(D - A^{k+1} - E_1^{k+1} + \frac{Y^k}{\mu_k} \right) \right\|_F^2 \quad (21)$$

上式对 E_2 求导并令为 0 后, 可得 E_2^{k+1} 的更新公式为:

$$E_2^{k+1} = \frac{[\mu_k D - \mu_k A^{k+1} - (\mu_k + \lambda_3) E_1^{k+1} + Y^k]}{2\lambda_2 + \mu_k} \quad (22)$$

步骤4 拉格朗日乘子可通过如下公式更新:

$$Y^{k+1} = Y^k + \mu_k (D - A^{k+1} - E_1^{k+1} - E_2^{k+1}) \quad (23)$$

重复步骤 1~步骤 4, 直至满足如下终止条件:

$$R1 = \frac{\max(e1, e2, e3)}{\|D\|_F} \leq \varepsilon_1, R2 = \frac{\|Y^{k+1} - Y^k\|}{\|D\|_F} \leq \varepsilon_2 \quad (24)$$

其中, $e1 = \|A^{k+1} - A^k\|_F$, $e2 = \|E_1^{k+1} - E_1^k\|_F$, $e3 = \|E_2^{k+1} - E_2^k\|_F$, $\varepsilon_1 > 0$ 和 $\varepsilon_2 > 0$ 均为误差常数. 同时, 为加快迭代, 参数 μ 可采用如下方式更新^[23]:

$$\mu_{k+1} = \max(\rho \mu_k, \mu_{\max}) \quad (25)$$

其中, $\rho > 1$ 为放大倍数, μ_{\max} 为 μ_k 上界. 综上所述, 复杂运动背景下所提基于群稀疏的动目标检测方法步骤如算法 1 所示.

算法 1 基于群稀疏的运动目标检测方法

输入: 图像序列 $D = [I_1, I_2, \dots, I_n] \in \mathbb{R}^{N \times D}$

初始化: $Y^0, A^0, E_1^0, \varepsilon_1, \varepsilon_2, \mu_0, \mu_{\max}, \rho, k = 0, R1 = R2 = \infty$

while $R1 > \varepsilon_1$ 或 $R2 > \varepsilon_2$ do

1. 固定 E_1, E_2 , 通过式(13)更新 A
2. 固定 A, E_2 , 通过式(19)更新 E_1
3. 固定 A, E_1 , 通过式(22)更新 E_2
4. 通过式(23)更新拉格朗日乘子 Y
5. 通过式(25)更新惩罚参数 μ_k
6. $k = k + 1$

End while

输出: A, E_1, E_2

4 实验及分析

本节选择 I2R^[24]、UCSD^[25]、Wallflower^[26]和 CDnet-2014^[27] 数据集中 Airport, SwitchLight, WaterSurface, Rain, WavingTrees, Boats, Bottle, Fountain02, Bootstrap, Camouflage 及 ForegroundAperture 共 11 个视频序列作为测试集(基本信息及主要挑战因素如表 1 所示), 通过与 RPCA^[4], GoDec^[6], PRMF^[7], DECOLOR^[8](DEC), MoG-RPCA^[9](MoG), OMoGMF^[28]及 LSD^[29]等 7 个主流目标

检测算法对比以验证复杂动态背景下所提方法有效性. 实验环境: 处理器 i7-7700, 内存 8GB, MATLAB R2017b. 评价指标: 准确率(Precision), 召回率(Recall)和 F 值(F-measure), 定义如下^[30]:

$$\begin{aligned} \text{Precision} &= \frac{\text{TP}}{\text{TP} + \text{FP}} & \text{Recall} &= \frac{\text{TP}}{\text{TP} + \text{FN}} \\ \text{F-measure} &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \end{aligned} \quad (26)$$

其中, 真阳性(True Positive, TP)为正确分类为前景像素数目, 假阳性(False Positive, FP)为误分类为前景而实际为背景像素数目, 假阴性(False Negative, FN)为被错误分类为背景而实际为前景像素的数目, F-measure 作为综合评价指标, 其值越大表明运动目标检测效果越好.

4.1 参数设置

依据实验, 设置 $\lambda_1 = 2/\sqrt{MN}$, $\lambda_2 = 1.5/\sqrt{MN}$, $\lambda_3 = 0.5/\sqrt{MN}$, $\mu_0 = 1.5/\|D\|_F$, $\mu_{\max} = 1 \times 10^7 \times \mu_0$, $\varepsilon_1 = \varepsilon_2 = 1 \times 10^{-5}$, $\rho = 1.1$. 由文献[14]可知, 参数 γ 应设置为大于 1 的较小实数, 且较大范围内变动对结果影响较小, 经多次试验得 $\gamma = 2$ 在各场景下均可取得较高 F-measure, 因而在以下试验中取 $\gamma = 2$.

表 1 测试视频序列基本信息及其挑战因素

视频序列	基本信息	挑战因素
Airport	室内场景, 176*144 分辨率, RGB 图像	遮挡
SwitchLight	室内场景, 160*128 分辨率, RGB 图像	光照变化
WaterSurface	室外场景, 160*128 分辨率, RGB 图像	动态背景, 徘徊目标
Rain	室外场景, 308*228 分辨率, 灰度图像	动态背景
WavingTrees	室外场景, 160*120 分辨率, RGB 图像	动态背景
Boats	室外场景, 320*240 分辨率, RGB 图像	动态背景
Bottle	室外场景, 304*224 分辨率, 灰度图像	动态背景
Fountain	室外场景, 432*288 分辨率, RGB 图像	动态背景
Bootstrap	室内场景, 160*120 分辨率, RGB 图像	遮挡, 动态背景
Camouflage	室内场景, 160*120 分辨率, RGB 图像	动态背景
ForegroundAperture	室内场景, 160*120 分辨率, RGB 图像	动态背景


4.2 定性分析

室内场景下, 所提方法及对比算法部分检测结果如图 2 所示, 其中第 1~5 行分别为 Airport, SwitchLight, Bootstrap, Camouflage 及 ForegroundAperture 场景序列. 由图 2(d)~(j)可知, RPCA 没有对前景实施空域约束, 因而检测结果较差; GoDec 基于双边随机投影方法迭代求解前背景, 没有将前景及运动背景先验信息包含进分解模型, 从而将众多运动背景像素判别为前景, 虚警率较高; PRMF 考虑高斯及拉普拉斯噪声场景下前背景稳健分离, 然而没有利用前景空域连续性及运动背景信息, 因而检测空洞较多, 检测结果不完整; DEC 基于马尔科夫随机场实施前景空

域平滑性约束, 从而对前景像素过检测, 进而导致检测虚警率较高; MoG 仅考虑基于混合高斯的噪声建模, 噪声抑制效果较好, 然而由于没有考虑前景空域信息以及背景运动信息, 因而所得前景充斥大量背景像素, 虚警率较高, 检测精度较差; OMoGMF 基于高斯混合建模噪声, 并基于时域相似性约束构建前背景分离似然模型, 从而可以获得较好的噪声抑制及目标检测性能, 然而由于其并未将前景空域完整性约束及运动背景信息包含进似然模型, 因而性能提升有限; LSD 基于结构稀疏范数建模稀疏前景, 利用运动显著性检测抑制运动背景, 从而改善目标检测性能同时降低检测虚警率, 然而由于结构稀疏范数

无法较好表征目标区域连续性,因而所得前景完整性较差;相较于上述对比算法,由图2(c)可得,所提方法基于超像素分割以确保前景空域完整性,基于Frobenius范数以表征非结构化运动背景,基于可近乎无偏估计秩函数的 γ 范数,而非过度惩罚较大奇异值

的核范数以有效建模低秩静态背景,从而在遮挡及光照变化等复杂场景下,所提方法均可较好抑制运动背景以降低检测虚警率,充分消除静态背景以改善背景噪声鲁棒性,有效约束前景空域连续性以提升目标检测完整性,进而改善目标检测性能。




(a)输入图像 (b)真实目标 (c)文本 (d)RPCA (e)GoDec (f)PRMF (g)DEC (h)MoG (i)OMoGMF (j)LSD

图2 室内场景检测结果对比

室外场景下,所提方法及对比算法部分检测结果如图3所示,图3中第1~6行分别为WaterSurface、Rain、WavingTrees、Boats、Bottle及Fountain02场景.由图3(d)~(f)可知,RPCA、GoDec及PRMF由于没有考虑运

动背景及前景空域连续性,因而动态背景抑制效果较差,检测结果存在大量噪声,虚警率较高,所检测徘徊目标存在明显拖影现象,且检测结果不够完整;由图3(g)、(h)可得,DEC利用马尔科夫随机场约束前景空



(a)输入图像 (b)真实目标 (c)文本 (d)RPCA (e)GoDec (f)PRMF (g)DEC (h)MoG (i)OMoGMF (j)LSD

图3 室外场景检测结果对比

域,MoG 基于混合高斯建模复杂场景噪声,因而 Rain 场景下二者可较完整地检测运动目标,然而,WaterSurface 和 WavingTrees 场景下虚警率仍然较高;由图 3(i)可知,OMoGMF 利用高斯混合建模噪声,并基于时域相似性约束构建检测模型,检测效果较好,然而未考虑前景连续性约束,因而检测结果不够完整;由图 3(j)可知,LSD 利用结构稀疏范数建模目标前景,利用运动显著性地抑制运动背景以降低检测虚警率,然而由于没有考虑前景区域连续性,因而所得检测结果完整性较差;相较于上述算法,由图 3(c)可得,动态背景及徘徊目标等复杂场景下,所提方法均可较好抑制运动背景噪声、充分消除静态背景、有效约束前景空域完整性,进而较好

地实现运动目标检测.

4.3 定量分析

上述 11 个室内外视频序列条件下,所提方法及对比算法所得 Precision, Recall 和 F-measure 值如图 4 所示,其中,各场景下所得评价指标均值对比如图 4 右下角子图所示,其详细数值如表 3 所示,加粗字体表示三者最大值,下划线表示次最大值. 由图 4 可知,各场景下所提方法均有较高 Precision, Recall 和 F-measure 值,表明不同场景下所提方法均可实现有效且稳定的目标检测. 此外,由表 2 可知,相较于对比算法,所提运动目标检测方法平均评价指标均为最高,从而表明复杂场景下所提运动目标检测方法检测性能优于对比算法.

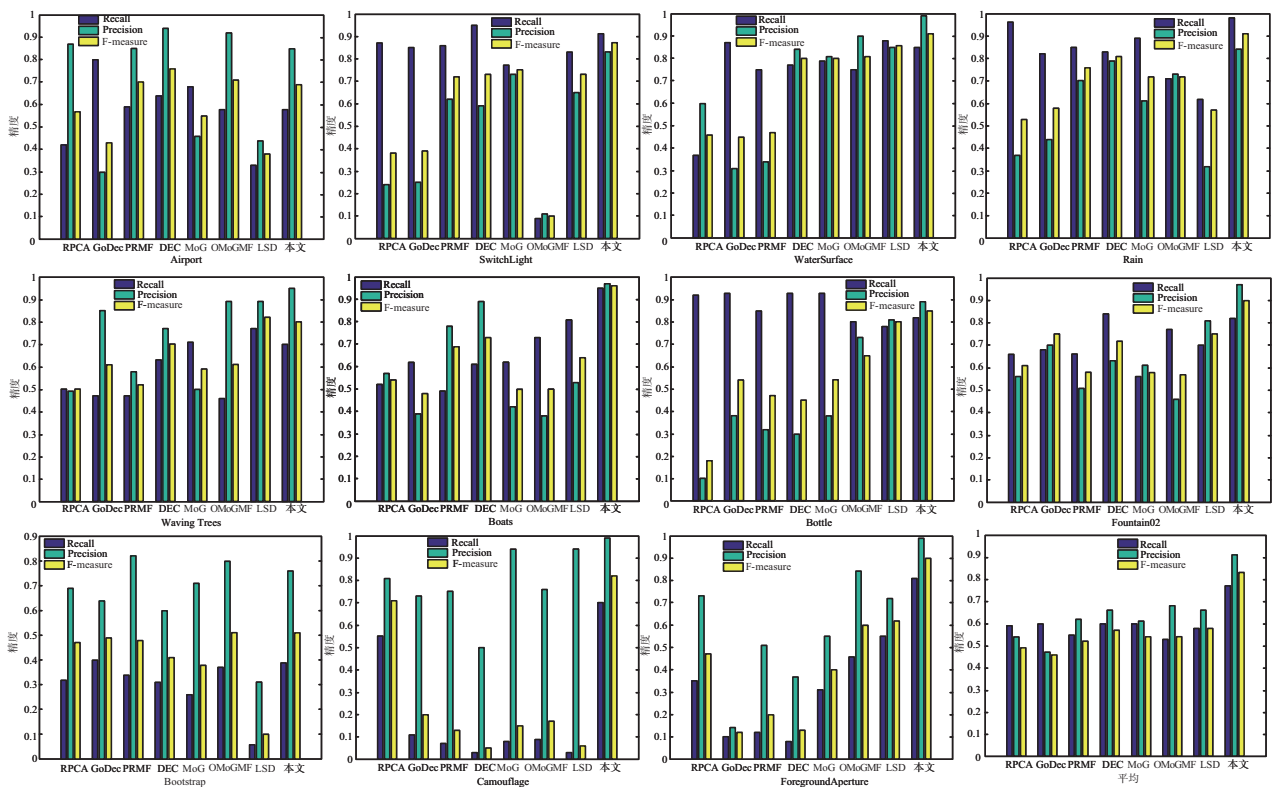


图 4 不同场景下运动目标准确率、召回率及 F 值对比

表 2 不同场景下各算法准确率、召回率及 F 值平均值对比

评价指标	RPCA	GoDec	PRMF	DEC	MoG	OMoGMF	LSD	本文
Precision	0.5840	0.4655	0.6164	0.6574	0.6103	<u>0.6836</u>	0.6244	0.9139
Recall	0.5873	<u>0.6052</u>	0.5497	0.6030	0.6014	0.5265	0.5542	0.7744
F-measure	0.4932	0.4516	0.5108	<u>0.5718</u>	0.5427	0.5402	0.5446	0.8293

5 结论

基于低秩及稀疏分解理论,本文提出复杂动态背景下基于群稀疏的运动目标检测方法. 首先利用 γ 范数近乎无偏近似秩函数的特性以约束静态背景矩阵;为充分利用前景目标边界信息,使用超像素分割算法

过分割每帧图像以生成同性区域并以此定义群稀疏范数进而约束稀疏前景矩阵;此外,为增强低秩静态背景及动态背景的可分离性,引入非相干项约束以避免运动目标同时出现在二者之中. 实验结果表明,复杂动态背景下,与现有 RPCA, GoDec, PRMF, DEC, MoG, OMoGMF 及 LSD 等主流算法相比,所提运动目标检测方法可较

好抑制动态背景噪声,从而实现具有较高检测精度及鲁棒性的前景检测。

参考文献

- [1] Yang Y C, Loquercio A, Scaramuzza D, et al. Unsupervised moving object detection via contextual information separation[A]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Long Beach, CA, USA : IEEE, 2019. 879 – 888.
- [2] Saxena T, Tripathi V, Chandola A, et al. Robust moving object detection and tracking framework using linear phase FIR filter[A]. International Conference on Emerging Technologies in Computer Engineering[C]. Singapore: Springer, 2019. 34 – 44.
- [3] B S, Tom A J, George S N. Simultaneous denoising and moving object detection using low rank approximation[J]. Future Generation Computer Systems, 2019, 90: 198 – 210.
- [4] Candès E J, Li X D, Ma Y, et al. Robust principal component analysis[J]. Journal of the ACM, 2011, 58(3): 1 – 37.
- [5] XUE Ya-wen, GUO Xiao-jie, CAO Xiao-chun. Motion saliency detection using low-rank and sparse decomposition [A]. 2012 IEEE International Conference on Acoustics, Speech and Signal Processing[C]. Kyoto, Japan: IEEE, 2012. 1485 – 1488.
- [6] ZHOU Tian-yi, TAO Da-cheng. Godec: Randomized low-rank & sparse matrix decomposition in noisy case[A]. Proceedings of the 28th International Conference on Machine Learning[C]. Sydney: ICML,2011. 33 – 40.
- [7] WANG Nai-yan, YAO Tian-sheng, WANG Jing-dong, et al. A probabilistic approach to robust matrix factorization. European Conference on Computer Vision[C]. Berlin, Germany: Springer, 2012. 126 – 139.
- [8] Zhou X W, Yang C, Yu W C. 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.
- [9] ZHAO Qian, MENG De-yu, XU Zong-ben, et al. Robust principal component analysis with complex noise[A]. 31st International Conference on Machine Learning[C]. Beijing, China: Microtome,2014. 55 – 63.
- [10] 周伟, 孙玉宝, 刘青山, 等. 运动目标检测的 l_0 群稀疏 RPCA 模型及其算法[J]. 电子学报, 2016, 44(3): 627 – 632.
Zhou W, Sun Y B, Liu Q S, et al. l_0 group sparse RPCA model and algorithm for moving object detection[J]. Acta Electronica Sinica, 2016, 44(3): 627 – 632. (in Chinese)
- [11] Gao Z, Cheong L F, Wang Y X. Block-sparse RPCA for salient motion detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(10): 1975 – 1987.
- [12] Achanta R, Shaji A, Smith K, et al. SLIC Superpixels[R]. Lausanne, Swiss Confederation: EPFL, 2010.
- [13] Zhang H M, Yang J, Xie J C, et al. Weighted sparse coding regularized nonconvex matrix regression for robust face recognition[J]. Information Sciences, 2017, 394/395: 1 – 17.
- [14] WANG Shu-sen, LIU De-hua, ZHANG Zhi-hua. Nonconvex relaxation approaches to robust matrix recovery[A]. Twenty-Third International Joint Conference on Artificial Intelligence[C]. Beijing, China: AAAI Press, 2013. 1764 – 1770.
- [15] Cao W F, Sun J, Xu Z B. Fast image deconvolution using closed-form thresholding formulas of $L_q(Q=12, 23)$ regularization[J]. Journal of Visual Communication and Image Representation, 2013, 24(1): 31 – 41.
- [16] Shi J B, Malik J. Normalized cuts and image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888 – 905.
- [17] Levinshtein A, Stere A, Kutulakos K N, et al. TurboPixels: Fast superpixels using geometric flows[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2290 – 2297.
- [18] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274 – 2282.
- [19] Sun Y B, Liu Q S, Tang J H, et al. Learning discriminative dictionary for group sparse representation[J]. IEEE Transactions on Image Processing, 2014, 23(9): 3816 – 3828.
- [20] LIU Bo, YUAN Xiao-tong, YU Yang, et al. Decentralized robust subspace clustering[A]. Thirtieth AAAI Conference on Artificial Intelligence[C]. Phoenix, Arizona USA: AAAI Press,2016. 3539 – 3545.
- [21] 王佰玲, 田志宏, 张永铮. 奇异值分解算法优化[J]. 电子学报, 2010, 38(10): 2234 – 2239.
Wang B L, Tian Z H, Zhang Y Z. Optimization of singular vector decomposition algorithm[J]. Acta Electronica Sinica, 2010, 38(10): 2234 – 2239. (in Chinese)
- [22] Liu G C, Lin Z C, Yan S C, et al. Robust recovery of subspace structures by low-rank representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence

- gence, 2013, 35(1): 171 – 184.
- [23] LIN Zhou-chen, CHEN Min-ming, et al. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[EB/OL]. <https://arxiv.org/pdf/1009.5055.pdf>, 2010.
- [24] Li L Y, Huang W M, Gu Irene Y H, et al. Statistical modeling of complex backgrounds for foreground object detection[J]. IEEE Transactions on Image Processing, 2004, 13(11): 1459 – 1472.
- [25] Mahadevan V, Vasconcelos N. Spatiotemporal saliency in dynamic scenes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(1): 171 – 177.
- [26] Toyama K, Krumm J, Brumitt B, et al. Wallflower: Principles and practice of background maintenance[A]. Proceedings of The Seventh IEEE International Conference on Computer Vision[C]. Kerkyra, Greece: IEEE, 1999. 255 – 261.
- [27] Wang Yi, Jodoin P M, Porikli F, et al. CDnet 2014: An expanded change detection benchmark dataset[A]. 2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops[C]. Columbus, USA: IEEE, 2014. 393 – 400.
- [28] Yong H W, Meng D Y, Zuo W M, et al. Robust online matrix factorization for dynamic background subtraction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(7): 1726 – 1740.
- [29] Liu X, Zhao G Y, Yao J W, et al. Background subtraction based on low-rank and structured sparse decomposition [J]. IEEE Transactions on Image Processing, 2015, 24(8): 2502 – 2514.
- [30] Yang H H, Qu S R. Real-time vehicle detection and counting in complex traffic scenes using background sub-


traction model with low-rank decomposition[J]. IET Intelligent Transport Systems, 2018, 12(1): 75 – 85.

作者简介



王洪雁 男, 1979年5月生于河南南阳. 2011年毕业于西安电子科技大学获信号与信息处理专业博士学位, 现为浙江理工大学信息学院特聘教授、硕士生导师. 主要研究方向为: 阵列信号处理、机器视觉、深度学习等.

E-mail: gglongs@163.com



张海坤 男, 1995年4月生于安徽阜阳. 现为大连大学信息学院控制科学与工程专业硕士研究生, 主要研究方向为计算机视觉.

E-mail: 707274821@qq.com



罗宇华 男, 1979年生于江西吉安, 上海精密计量测试研究所高级工程师, 研究方向为图像处理、元器件可靠性.

E-mail: luoyuhua@163.com



汪祖民 男, 1975年生于河南省信阳, 大连大学信息工程学院教授、硕士生导师, 研究方向为物联网、智慧城市.

E-mail: wangzumin@dlu.edu.cn