

雨雪天气条件下的运动目标检测

杨国亮, 喻丁玲*, 王杨, 王艳芳

江西理工大学电气工程与自动化学院, 江西 赣州 341000

摘要 针对雨雪天气条件下的运动目标检测受到天气的影响较大, 提出一种融合全变分(TV)正则化和 Rank-1 约束鲁棒主成分分析(RPCA)模型的视频序列运动目标检测算法。利用 RPCA 这一工具, 在低秩稀疏分解框架下, 采用 Rank-1 约束描述背景层的强低秩性, 利用 TV 正则化结合 L_1 范数对前景目标的稀疏性和空间连续性进行约束, 从而弥补现有 RPCA 模型的不足。针对所提模型, 采用交替迭代乘法的思想结合增广拉格朗日乘法对目标函数进行优化求解。实验结果表明, 所提算法不仅能够准确检测出运动目标, 而且具有较短的运行时间, 这为视频的实时检测提供参考。与其他同类算法相比, 所提算法不仅检测效果更佳, 而且在 F 测度值、召回率和准确率的定量评价中均有优越性。

关键词 机器视觉; 鲁棒主成分分析; 全变分正则化; Rank-1 正则化; 运动目标检测

中图分类号 TP391.4 **文献标志码** A

doi: 10.3788/LOP57.241507

Moving Object Detection Under Rain and Snow Weather Conditions

Yang Guoliang, Yu Dingling*, Wang Yang, Wang Yanfang

School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China

Abstract In view of the fact that the detection of moving targets in real-time video are greatly affected by weather conditions. Herein, a video sequence moving target detection algorithm that combines total variation (TV) regularization and a Rank-1 constrained robust principal component analysis (RPCA) model is proposed. Using RPCA as a tool in the framework of low-rank sparse decomposition, the Rank-1 constraint is used to describe the strong low-rank of the background layer, and the TV regularization combined with the L_1 norm is used to perform the sparseness and spatial continuity of the foreground target constraints to compensate for the deficiencies of the existing RPCA model. Aiming at the proposed model, the idea of alternating iterative multiplier method combined with augmented Lagrangian multiplier method is used to optimize the objective function. Experimental results show that the proposed algorithm can not only accurately detect moving targets but also has a shorter running time, which provides a reference for real-time video detection. Compared with other similar algorithms, the proposed algorithm not only has better detection effect but also provides enhanced quantitative evaluation of F measurement value, recall rate, and accuracy rate.

Key words machine vision; robust principal component analysis; total variation regularization; Rank-1 regularization; moving object detection

OCIS codes 150.0155; 150.1135

1 引言

在视频监控系统中, 运动目标检测^[1]是识别视频数据中 useful 信息的重要任务之一, 如入侵检测、边缘对象和交通数据采集等, 实时环境中的运动目标

检测具有重要的应用价值。自然环境中, 视频质量会受到动态背景、光照变化、遮挡和相机抖动等影响, 但现已有较好的解决方法。然而, 恶劣天气下的运动目标检测仍然是一个难题, 尤其是雨雪天气下的运动目标检测面临着很大挑战, 如空中有不规律

收稿日期: 2020-05-08; 修回日期: 2020-06-11; 录用日期: 2020-06-17

基金项目: 国家自然科学基金(51365017)、江西省教育厅科技计划(GJJ190450)

* E-mail: ydl_1001@163.com

飘动的雪花,这些背景噪声^[2]会干扰目标的检测;雪天背景亮度较大,会导致目标物不清晰等,这为高精度的运动目标检测带来巨大挑战。

背景差分法是经典的运动目标检测算法之一,其核心是利用当前图像与背景图像的差分来检测运动目标,但该方法只有在静态相机、恒定光照和静态背景下效果良好。近年来,鲁棒主成分分析(RPCA)^[3]在计算机视觉的许多研究中得到了广泛的应用,然而其只能在静态背景下工作,原因在于现实场景的背景在本质上并不总是静态的,物体的运动也没有规律。为了解决RPCA模型中存在的不足,国内外学者进行了大量的研究,Guyon等^[4-6]在RPCA模型的基础上进行了修改,改进后的模型可以取得较好的效果。在此基础上,Guo等^[7-10]将整体变分(TV)正则化引入稀疏性约束中,可以对视频的前景空间进行更有效的建模。Shijila^[11]提出了基于低秩近似结合TV正则化运动目标检测(DNLRITV)方法,该方法是RPCA框架的扩展,对视频中的噪声有较好的去除效果。李艳获等^[12]提出了基于超像素时空特征的视频显著性检测方法,该方法可对图像进行超像素分割以提取颜色梯度和运动梯度特征,从而构建超像素级时空梯度图。Li等^[13]提出了分割和显著性约束RPCA(SSC-RPCA)方法,该方法可以应对动态背景和显著性约束并能够检测到缓慢移动的对象,但是未考虑视频中的噪声,所以在实际应用中可能会影响检测效果。

虽然应用RPCA模型在目标检测上取得了很多成果,但大多数算法分别将背景和前景估计为低秩和稀疏分量,原因在于这些算法未同时利用背景和前景的结构特性,显然在恶劣天气这种极端的天气下无效。鉴于此,本文首先基于运动目标在时间和空间上的连续性以及背景在时间上的相关性,利用RPCA这一模型,在低秩稀疏分解框架下,采用Rank-1正则化约束描述背景层的强低秩性,其次进一步细化RPCA模型中的动态分量,将其看作平滑视频前景和稀疏噪声沿时空域的叠加。然后采用TV正则化并结合 L_1 范数对前景目标的时空平滑性和噪声的稀疏性进行约束,从而弥补现有RPCA模型的不足。最后采用交替迭代的思想和推广拉格朗日乘子法(ALM)对目标函数进行优化求解,从而实现恶劣天气条件下的目标检测。实验结果表明,所提算法不仅能够检测出真实的运动前景,而且与同类算法相比具有较高的精度和较快的运行速度。

2 相关知识

2.1 低秩稀疏矩阵分解

由于视频数据中的背景层和前景层具有固有的低秩稀疏结构,将RPCA框架用于视频目标检测可以取得较好的效果,其核心思想是将视频矩阵分解成低秩矩阵和稀疏矩阵。假设输入视频流为 $\mathbf{V} \in \mathbf{R}^{m \times n \times p}$,其中 p 表示帧数, m 和 n 分别表示高度和宽度。首先将视频序列排列为一个列向量,所有视频帧组成的矩阵为二维观测数据矩阵 $\mathbf{O} \in \mathbf{R}^{m \times n \times p}$,这是将三维视频转换到二维空间上。根据背景矩阵与前景矩阵分别具有低秩性与稀疏性,可以将观测数据矩阵 \mathbf{O} 分成两部分,即低秩矩阵 $\mathbf{L} \in \mathbf{R}^{m \times n \times p}$ 和稀疏矩阵 $\mathbf{S} \in \mathbf{R}^{m \times n \times p}$,表达式为

$$\min_{\mathbf{L}, \mathbf{S}} \text{rank}(\mathbf{L}) + \lambda \|\mathbf{S}\|_0, \quad \text{s. t. } \mathbf{O} = \mathbf{L} + \mathbf{S}, \quad (1)$$

式中: λ 表示缩放因子,用来平衡背景和运动目标之间的比重; $\text{rank}(\mathbf{L})$ 表示矩阵 \mathbf{L} 的秩; $\|\mathbf{S}\|_0$ 表示矩阵 \mathbf{S} 的 L_0 范数。由于 $\text{rank}(\mathbf{L})$ 和 $\|\mathbf{S}\|_0$ 都是非凸的,故需要在此基础上对模型进行修正,现有可行的方法是使用核范数来逼近矩阵的秩,即使用矩阵的 L_1 范数来代替矩阵的 L_0 范数,故(1)式可以表示为

$$\min_{\mathbf{L}, \mathbf{S}} \|\mathbf{L}\|_* + \lambda \|\mathbf{S}\|_1, \quad \text{s. t. } \mathbf{O} = \mathbf{L} + \mathbf{S}, \quad (2)$$

式中: $\|\mathbf{L}\|_*$ 表示矩阵 \mathbf{L} 的核范数,即 \mathbf{L} 的奇异值之和; $\|\mathbf{S}\|_1$ 表示矩阵 \mathbf{S} 的 L_1 范数。通过求解此模型,可以求解出低秩背景部分和稀疏前景部分。从(2)式可以看到,RPCA模型只对没有噪声干扰的数据施加低秩约束,而忽略 \mathbf{O} 矩阵中列之间的关系。

2.2 TV范数

视频前景中的移动物体在连续帧之间是连续的,并且每帧的移动物体在空间域的局部区域也是平滑的,这种先验称为视频前景的时空连续性,将各向异性的三维总变异量施加于堆叠排列后的视频数据矩阵 \mathbf{U} ,可以实现对前景平滑度的正则化。实验要处理的视频属于三维空间,三维全变分可表示为

$$\|\mathbf{U}\|_{\text{TV}} = \sum_{i,j} \left[|U_x(i,j,t)| + |U_y(i,j,t)| + |U_z(i,j,t)| \right], \quad (3)$$

式中: $U_x(i,j,t)$ 、 $U_y(i,j,t)$ 和 $U_z(i,j,t)$ 分别表示 x 轴、 y 轴和 z 轴在 t 时刻像素点 (i,j) 的灰度值,则分别表示为

$$\begin{cases} U_x(i,j,t) = U(i+1,j,t) - U(i,j,t) \\ U_y(i,j,t) = U(i,j+1,t) - U(i,j,t) \\ U_z(i,j,t) = U(i,j,t+1) - U(i,j,t) \end{cases} \quad (4)$$

根据文献[14],各向异性TV范数是将不同点

的所有向量范数相加,得到各向异性全变差范数和各向同性全变差范数。

3 所提算法

实验主要目的是在雨雪环境下实现视频序列的

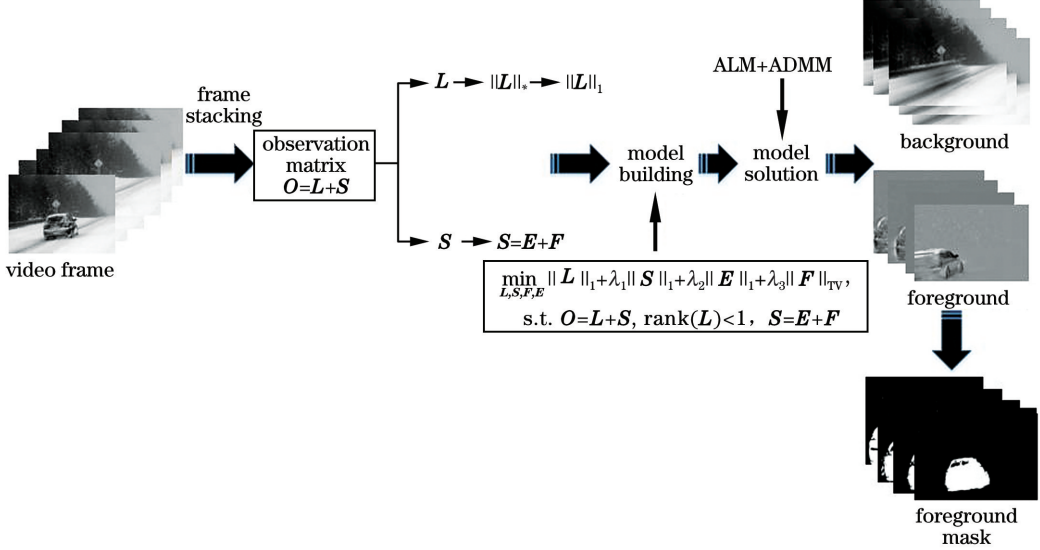


图1 所提算法的框架

Fig. 1 Framework of proposed algorithm

3.1 框架分析

实验主要考虑雨雪天气条件下的目标检测情况,所以将天空中飘舞的雪花或雨夹雪看作前景部分的噪声,因此可以将 S 分为 $E \in \mathbf{R}^{m \times n \times p}$ 和 $F \in \mathbf{R}^{m \times n \times p}$, 即 $S = E + F$, 则 O 与 S 可表示为

$$\begin{aligned} \min_{L,S,E,F} \text{rank}(L) + \lambda_1 \|S\|_0 + \lambda_2 \|E\|_1 + \lambda_3 \|F\|_1, \\ \text{s. t. } O = L + S, S = E + F. \end{aligned} \quad (5)$$

由于 $\text{rank}(\cdot)$ 和 L_0 都是非凸的,所以这是一个 NP(Non-deterministic Polynomial) 难问题,因此使用核范数和 L_1 范数来代替。实验的背景环境复杂,既有动态干扰,也有噪声干扰。低阶矩阵分解(6)式缺乏合适的空间约束,所以不能有效地去除噪声。从 2.2 节提到的 TV 模型来看,其可以增强空间平滑度以及保存边缘信息,所以可以将 L_1 范数和 TV 正则化结合到前景部分的目标函数中,构造出新的模型公式,即

$$\begin{aligned} \min_{L,S,E,F} \|L\|_* + \lambda_1 \|S\|_1 + \lambda_2 \|E\|_1 + \lambda_3 \|F\|_{TV}, \\ \text{s. t. } O = L + S, S = E + F. \end{aligned} \quad (6)$$

若环境发生变化,则低秩部分奇异值的物理含义可能被忽略,这将导致低秩分量的估计结果有偏差,使得核范数在复杂环境下无法揭示视频帧的基本重复特性。与背景先验相比,使用 Rank-1^[15] 约束的一个优点是可以通过最小化除目标秩外背景分

目标检测,所提算法的框架如图 1 所示。其中 F 表示检测出的真实前景, E 表示动态噪声部分, λ_1 、 λ_2 和 λ_3 表示平衡参数因子, $\|L\|_1 = |\text{rank}(L) - 1| = \sum_{i=2} \sigma_i(L)$, $\sigma_i(L)$ 表示矩阵 L 的第 i 个奇异值, ADMM 表示交替方向乘子。

量的奇异值来保留主信息,所以基于 Rank-1 约束 RPCA 的视频表示可以更好地编码视频序列中的静态成分,即潜在背景知识。Rank-1 正则化不仅能够保留矩阵的第一个奇异值,而且最小化剩余秩中的动态分量,所以 Rank-1 正则化适用于本实验环境。通过对基于 Rank-1 正则化的背景先验的分析可知,这里仅需要最小化目标函数中奇异值的部分和^[16],所以最终的最优化模型为

$$\begin{aligned} \min_{L,S,E,F} \|L\|_1 + \lambda_1 \|S\|_1 + \lambda_2 \|E\|_1 + \lambda_3 \|F\|_{TV}, \\ \text{s. t. } O = L + S, \text{rank}(L) \leq 1, S = E + F. \end{aligned} \quad (7)$$

3.2 模型求解

首先,将(7)式写成增广拉格朗日形式,表达式为

$$\begin{aligned} \min_{L,S,E,F} \|L\|_1 + \lambda_1 \|S\|_1 + \lambda_2 \|E\|_1 + \lambda_3 \|F\|_{TV} + \\ \langle X, O - L - S \rangle + \langle Y, S - E - F \rangle + \\ \frac{\mu}{2} \|O - L - S\|_F^2 + \frac{\mu}{2} \|S - E - F\|_F^2, \end{aligned} \quad (8)$$

式中: μ 表示正惩罚参数; $X, Y \in \mathbf{R}^{m \times n \times p}$ 表示拉格朗日乘子; $\langle \cdot \rangle$ 表示矩阵内积; $\|\cdot\|_F^2$ 表示弗洛内尼斯(Frobenius)范数。若要同时优化这些变量是非常困难的,因此采用 ADMM 法^[17] 将其他变量设为常数以求出一个变量的最小值,从而得到近似解。

4 实验结果与分析

为了对所提算法进行验证,实验是在 MATLAB 2018 环境下实现的,所选用的计算机是 64 位的操作系统,8 GB 的 RAM,处理器为 Intel(R)Core(TM) i5-8250U CPU@1.60 GHz 四核。采用 CDCNET 2014 数据集中的“bad weather”序列开展实验,CDCNET 2014 数据集中包含每个视频的真实前景,之后将与实验所得结果进行比较。在相同的条件下,将所提算法与其他现有算法进行比较。

为了验证所提算法的性能,所有视频都选用连续的 20~40 frame 图像进行检测,平衡因子 $\lambda_1 = 0.1\lambda$ 、 $\lambda_2 = 2\lambda$ 和 $\lambda_3 = \lambda$,其中 $\lambda = 1/\sqrt{\max(m,n)} \times p$ 。在相同的条件下,将所提算法与其他 5 种同类算法(DECOLOR^[6]、TVRPCA^[7]、DNLRL1TV^[11]、HOSVD^[18]和 OSTD^[19])进行对比,实验结果如图 2 所示。图 2(a)和图 2(b)为“bad weather”序列中的“暴雪(blizzard)”序列,其中图 2(a)为第 1096 frame 图像,图 2(b)为第 1111 frame 图像,该

场景为典型的小目标场景且目标排列紧密,目标物已用方框来标记;图 2(c)和图 2(d)为“降雪(snowfall)”序列,其中图 2(c)为第 807 frame 图像,图 2(d)为第 832 frame 图像,该场景的目标有阴影和被雪覆盖的表面,而且场景中有光照变化;图 2(e)和图 2(f)为“雨夹雪(wet snow)”序列,其中图 2(e)为第 680 frame 图像,图 2(f)为第 688 frame 图像,该场景是典型的背景噪声场景;图 2(g)为“暴风雪(blizzard)”序列,其为第 3249 frame 图像,在图像中加入高斯噪声来模拟除雪花外可能存在其他噪声干扰的情况;图 2(h)为“溜冰(skating)”序列,其为第 5692 frame 图像,该场景的背景有遮挡;图 2(i)为“降雪(snowfall)”序列,该环境下车辆的尾部被雪遮挡;图 2(j)为“船(boat)”序列,其为动态背景序列,该环境中不仅有树叶摆动,而且有水纹波动。从第一列到最后一列分别为当前帧、背景、真实前景、所提算法、DECOLOR 算法^[6]、TVRPCA 算法^[7]、DNLRL1TV 算法^[11]、HOSVD 算法^[18]和 OSTD 算法^[19]的检测结果。




图 2 不同序列的定性对比结果。暴雪序列(a)第 1096 frame 图像,(b)第 1111 frame 图像;降雪序列(c)第 807 frame 图像,(d)第 832 frame 图像;雨夹雪序列(e)第 680 frame 图像,(f)第 688 frame 图像;(g)暴风雪序列中第 3249 frame 图像;(h)溜冰序列中第 5692 frame 图像;(i)降雪序列;(j)船序列

Fig. 2 Qualitative comparison results of different sequences. Blizzard sequence (a) 1096th frame images; (b) 1111th frame images; snowfall sequence (c) 807th frame images; (d) 832th frame images; sleet sequence (e) 680th frame images, (f) 688th frame images; (g) 3249th frame images in blizzard sequence; (h) 5692th frame images in skating sequence; (i) snow sequence; (j) ship sequence

从图 2 可以看到,对于小目标和被雪覆盖的目标表面,DECOLOR 算法和 TVRPCA 算法能够检测大面积物体,但会将小物体当作背景来处理,DNLRL1TV 算法能够检测完整的目标,但检测结果有虚警现象,HOSVD 算法不能正确检测运动目标,OSTD 算法检测的目标不完整,而所提算法有较好的检测效果,检测的目标物清晰且较完整,原因在于所提算法在前景部分使用 Rank-1 代替核范数约束,所以对前景、背景分离得更清晰;对于阴影的处理和光照变化的适应,TVRPCA 算法的检测效果不佳,检测结果只能保持基本边缘,空洞很大,HOSVD 算法和 OSTD 算法检测的目标假阳性背景很多,DECOLOR 算法有少量的误检测区域和虚警现象,所提算法和 DNLRL1TV 算法有较好的检测效果,未发生误检测,但所提算法检测的边缘更完整;对于动态噪声的抑制,DECOLOR 算法对动态噪声的抑制效果较好,但检测的目标物不完整,TVRPCA 算法检测的背景噪声较严重,HOSVD 和 OSTD 算法的去噪效果较差且检测的目标空洞,所

提算法和 DNLRL1TV 算法都有较好的检测效果,目标物都较完整;对于强噪声和动态场景,所提算法检测的目标较清楚,基本能够克服环境对检测结果的影响,而其他 5 种算法的去噪性能或检测目标的完整性都逊于所提算法。

为了定量分析各种算法的性能,将检测的前景和背景作为分类问题,令 TP 为正确检测出前景像素数目,TN 为正确检测出的背景像素数目,FN 为被检测为前景的背景像素数目,即漏检的前景点,FP 为被检测为背景的前景像素数目,即误检的前景点,TP+FP 为被检测出的所有前景像素的数目,TP+FN 为真实前景的像素数目。实验采用的三项指标:1)召回率 $R = N_{TP} / (N_{TP} + N_{FN})$; 2)准确率 $P = N_{TP} / (N_{TP} + N_{FP})$; 3)F 测度值, $F = 2 \times P \times R / (P + R)$ 。

定量对比结果如表 1 所示,准确率、召回率和 F 测度值都是越大越好,表中最好的指标已加粗。从表 1 可以看到,所提算法的各项指标均优于其他算法,表明所提算法可以取得良好的效果。

表 1 不同算法的三项指标测量值

Table 1 Measurement values of three indicators of different algorithms

Image	DECOLOR			TVRPCA			DNLRL1TV			HOSVD			OSTD			Proposed algorithm		
	<i>P</i>	<i>R</i>	<i>F</i>	<i>P</i>	<i>R</i>	<i>F</i>	<i>P</i>	<i>R</i>	<i>F</i>	<i>P</i>	<i>R</i>	<i>F</i>	<i>P</i>	<i>R</i>	<i>F</i>	<i>P</i>	<i>R</i>	<i>F</i>
Fig. 2(a)	0.36	0.96	0.57	0.70	0.47	0.57	0.60	0.61	0.61	0.53	0.71	0.61	0.63	0.69	0.66	0.75	0.85	0.80
Fig. 2(b)	0.63	0.34	0.44	0.76	0.26	0.38	0.73	0.67	0.70	0.42	0.80	0.55	0.78	0.62	0.69	0.83	0.81	0.82
Fig. 2(c)	0.76	0.57	0.65	0.83	0.51	0.63	0.78	0.60	0.68	0.56	0.70	0.62	0.66	0.69	0.68	0.84	0.78	0.81
Fig. 2(d)	0.70	0.79	0.75	0.72	0.71	0.71	0.78	0.81	0.79	0.43	0.47	0.45	0.40	0.43	0.41	0.81	0.89	0.88
Fig. 2(e)	0.22	0.75	0.34	0.48	0.71	0.57	0.78	0.80	0.79	0.63	0.86	0.73	0.83	0.77	0.80	0.88	0.93	0.90
Fig. 2(f)	0.65	0.73	0.69	0.72	0.78	0.74	0.72	0.79	0.75	0.65	0.80	0.72	0.65	0.83	0.73	0.91	0.94	0.92
Fig. 2(g)	0.50	0.51	0.50	0.52	0.43	0.47	0.73	0.85	0.79	0.74	0.85	0.79	0.62	0.82	0.71	0.90	0.91	0.90

图 3 为相关参数对实验结果的影响,图 3(a)为 λ 对 F 测度值的影响,选用“snowfall”序列中的连续 35 frame 图像,图 3(b)为 μ 对 F 测度值的影响。

从图 3(a)可以看到,若 λ 值配置得当,则所提算法明显优于 RPCA 算法和 TVRPCA 算法,并且 λ 值在 $8 \times 10^{-3} \sim 10 \times 10^{-3}$ 这个范围内效果最好,

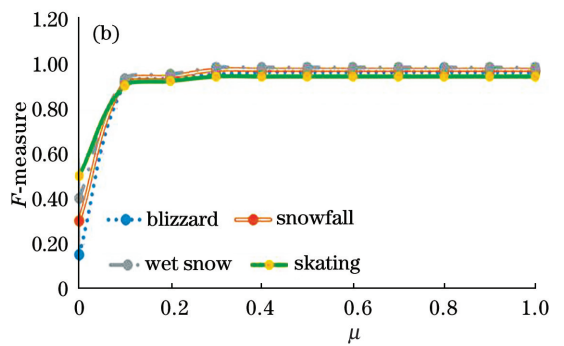
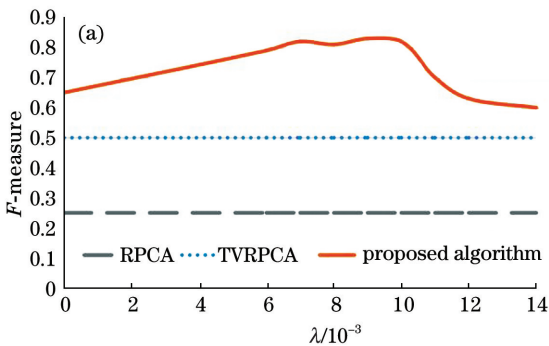


图 3 不同参数对 F 测度值的影响。(a) λ ; (b) μ

Fig. 3 Influence of different parameters on measured value of F. (a) λ ; (b) μ

可以证明所提算法的有效性。从图 3(b) 可以看到, 当 μ 值大于 0.2 时, F 测度值接近于 1, F 测度值越大, 说明所提算法检测的运动目标越接近真实。

为了验证所提算法在运行速度上的优势, 不同算法的运行速度对比结果如表 2 所示, 表中最好的

表 2 6 种算法的运行时间对比

Table 2 Comparison of running time of 6 algorithms

unit: s

Algorithm	Fig. 2(a)	Fig. 2(b)	Fig. 2(c)	Fig. 2(d)	Fig. 2(e)	Fig. 2(f)	Fig. 2(g)
Proposed algorithm	27.04	20.31	29.95	21.32	25.03	17.67	21.89
DECOLOR	57.83	46.12	67.90	62.98	71.87	62.95	69.03
TVRPCA	150.23	143.56	163.72	138.53	178.45	167.83	177.93
DNLRL1TV	34.32	19.42	28.43	27.23	36.53	33.38	37.93
HOSVD	62.04	52.42	73.63	62.59	71.58	62.66	58.29
OSTD	30.53	28.34	37.68	42.90	50.06	39.62	35.98

为了进一步验证所提算法在低秩背景部分采用 Rank-1 正则化而不是核范数约束的合理性, 分别在不同序列上对比这两种约束的性能, 检测对比结果如图 4 所示。图 4 从第一列到最后一列分别为当前帧、真实前景、低秩部分采用 Rank-1 约束和低秩部分采用核范数约束的检测结果, 图 4(a) 和图 4(b) 为“snowfall”序列的第 807 frame 图像和第 832 frame 图像; 图 4(c) 和图 4(d) 为“wet snow”序列的第 680 frame 图像和第 688 frame 图

指标已加粗。从表 2 可以看到, 除了图 2(c) 中 LRL1TV 算法最快外, 剩余序列则是所提算法最快。虽然所提算法和 LRL1TV 算法的处理速度上相近, 但所提算法的检测效果更佳。对比处理效果和运行速度, 所提算法不仅可以提高运行速度并且检测效果也更好。

像。从图 4 可以看到, 在背景部分采用 Rank-1 正则化约束的一个很大好处是可以最小化除运动目标以外噪声分量的奇异值来保留主要信息, 所以去噪性能更好, 减少背景模型初始化步骤中假阳性像素的数量, 能够准确检测出运动目标; 低秩部分采用核范数约束的方法虽然能够检测出运动目标, 但是对于运动目标以外的噪声去除效果差, 检测的目标出现空洞的现象。实验结果表明, 采用 Rank-1 正则化约束具有合理性。

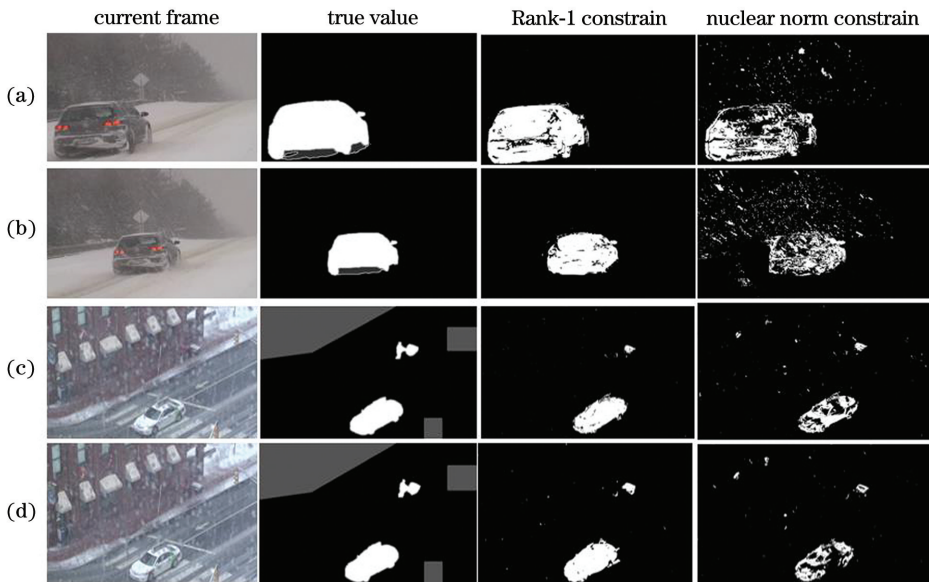


图 4 不同约束在不同序列上的对比结果。snowfall 序列(a)第 807 frame 图像, (b)第 832 frame 图像; wet snow 序列 (c)第 680 frame 图像, (d)第 688 frame 图像

Fig. 4 Comparison results of different constraints on different sequences. Snowfall sequence (a) 807th frame images, (b) 832th frame images; wet snow sequence (c) 680th frame images, (d) 688th frame images

5 结 论

为了有效地检测雨雪视频序列中的运动目标,利用RPCA模型这一工具,将Rank-1正则化、 L_1 范数和TV正则化运用在低秩稀疏分解的框架中以弥补现有RPCA模型的不足。通过优化求解所提模型可以有效地将前景目标从视频序列中分离出来,并分别在动态背景、噪声、弱阴影和光照变化以及有遮挡覆盖的情况下进行实验。实验结果表明,在背景部分采用Rank-1约束增强背景部分低秩性,再结合 L_1 范数和TV正则化约束前景部分,在此基础上进行更新也可以提高检测精度。与现有其他同类算法相比,所提算法不仅检测效果更佳,而且处理速度快,在 F 测度值、召回率和准确率的定量评价中具有优越性。

参 考 文 献

- [1] Zhu W J, Wang G L, Tian J, et al. Detection of moving objects in complex scenes based on multiple features[J]. Acta Optica Sinica, 2018, 38(6): 0612004.
朱文杰, 王广龙, 田杰, 等. 基于多特征的复杂场景运动目标检测[J]. 光学学报, 2018, 38(6): 0612004.
- [2] Zhou W J, Zou S, He D K, et al. Speckle noise reduction of holograms based on spectral convolutional neural network[J]. Acta Optica Sinica, 2020, 40(5): 0509001.
周文静, 邹帅, 何登科, 等. 频谱卷积神经网络实现全息图散斑降噪[J]. 光学学报, 2020, 40(5): 0509001.
- [3] Wright J, Ganesh A, Rao S, et al. Robust principal component analysis: exact recovery of corrupted low-rank matrices by convex optimization[R]. Urbana: University of Illinois, 2009.
- [4] Guyon C, Bouwmans T, Zahzah E H. Foreground detection based on low-rank and block-sparse matrix decomposition[C] // 2012 19th IEEE International Conference on Image Processing, September 30-October 3, 2012, Orlando, FL, USA. New York: IEEE, 2012: 1225-1228.
- [5] Shahid N, Kalofolias V, Bresson X, et al. Robust principal component analysis on graphs[C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 2812-2820.
- [6] 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.
- [7] Guo X J, Wang X G, Yang L, et al. Robust foreground detection using smoothness and arbitrariness constraints[M] // Fleet D, Pajdla T, Schiele B, et al. Computer vision-ECCV 2014. Lecture notes in computer science. Cham: Springer, 2014, 8695: 535-550.
- [8] Cao W F, Wang Y, Sun J, et al. Total variation regularized tensor RPCA for background subtraction from compressive measurements[J]. IEEE Transactions on Image Processing, 2016, 25(9): 4075-4090.
- [9] Xia S L, Sun H J, Chen B J. A regularized tensor decomposition method with adaptive rank adjustment for compressed-sensed-domain background subtraction[J]. Signal Processing: Image Communication, 2018, 62: 149-163.
- [10] Cao X C, Yang L, Guo X J. Total variation regularized RPCA for irregularly moving object detection under dynamic background[J]. IEEE Transactions on Cybernetics, 2016, 46(4): 1014-1027.
- [11] Shijila B. Moving object detection by low rank approximation and 11-TV regularization on RPCA framework[J]. Journal of Visual Communication and Image Representation, 2018, 56: 188-200.
- [12] Li Y D, Xu X P. Video saliency detection method based on spatiotemporal features of superpixels[J]. Acta Optica Sinica, 2019, 39(1): 0110001.
李艳获, 徐熙平. 基于超像素时空特征的视频显著性检测方法[J]. 光学学报, 2019, 39(1): 0110001.
- [13] Li Y, Liu G C, Liu Q S, et al. Moving object detection via segmentation and saliency constrained RPCA[J]. Neurocomputing, 2019, 323: 352-362.
- [14] Wu Z J, Wang Q, Wu Z H, et al. Total variation-regularized weighted nuclear norm minimization for hyperspectral image mixed denoising[J]. Journal of Electronic Imaging, 2016, 25(1): 013037.
- [15] Xue J, Zhao Y Q, Liao W Z, et al. Total variation and Rank-1 constraint RPCA for background subtraction[J]. IEEE Access, 2018, 6: 49955-49966.
- [16] Liu Y, Shan C F, Gao Q X, et al. Hyperspectral image denoising via minimizing the partial sum of singular values and superpixel segmentation[J].

Neurocomputing, 2019, 330: 465-482.

- [17] Boyd S. Distributed optimization and statistical learning via the alternating direction method of multipliers [J]. Foundations and Trends[®] in Machine Learning, 2010, 3(1): 1-122.
- [18] García-Magariño A, Sor S, Velazquez A. Data reduction method for droplet deformation experiments based on high order singular value

decomposition[J]. Experimental Thermal and Fluid Science, 2016, 79: 13-24.

- [19] Javed S, Bouwmans T, Jung S K. Stochastic decomposition into low rank and sparse tensor for robust background subtraction[C]//6th International Conference on Imaging for Crime Prevention and Detection (ICDP-15), July 15-17, 2015, London, UK. Cambridge: MIT Press, 2015: 5-7.