

DOI: 10.19650/j.cnki.cjsi.J1905517

基于广义非凸鲁棒主成分分析的视频前背景分离^{*}

杨永鹏¹, 杨真真^{2,3}, 李建林¹

(1. 南京信息职业技术学院网络与通信学院 南京 210023; 2. 南京邮电大学理学院 南京 210023;
3. 南京邮电大学 通信与网络技术国家工程研究中心 南京 210023)

摘 要:针对基于传统鲁棒主成分分析的视频前背景分离的精度不高的问题,提出了一种新的广义非凸鲁棒主成分分析(GNRPCA)模型。该模型分别采用广义核范数和广义范数来代替鲁棒主成分分析模型中的秩函数和 l_0 范数,以解决现有鲁棒主成分分析模型存在的对秩函数和稀疏度函数的替代函数过惩罚而导致逼近程度不佳的问题。然后采用交替方向乘子法(ADMM)对提出的GNRPCA模型进行求解。最后,将该算法用于视频前背景分离,进行仿真实验并对实验结果进行分析。实验结果证明提出的算法的平均 F -measure值为0.589 2,相对于截断核范数算法提高了13%以上,比其他的基于鲁棒主成分分析的视频前背景分离算法更具有优越性和有效性。

关键词: 鲁棒主成分分析;广义核范数;广义范数;交替方向乘子法;视频前背景分离

中图分类号: TN911.73 TH79 **文献标识码:** A **国家标准学科分类代码:** 510.40

Video foreground-background separation based on generalized nonconvex robust principal component analysis

Yang Yongpeng¹, Yang Zhenzhen^{2,3}, Li Jianlin¹

(1. School of Network and Communication, Nanjing Vocational College of Information Technology, Nanjing 210023, China;
2. School of Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;
3. National Engineering Research Center of Communication and Network Technology,
Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Aiming at the poor precision problem of video foreground-background separation based on traditional robust principal component analysis, this paper proposes a new model called generalized nonconvex robust principal component analysis (GNRPCA) model. This model adopts the generalized nuclear norm and generalized norm to replace the rank function and l_0 norm in the robust principal component analysis model, respectively, which can solve the problems of the excessive penalty for the surrogate functions of the rank function and sparsity function existing in traditional robust principal component analysis model, and leading to poor approaching degree. Then, the alternating direction method of multiplier (ADMM) is adopted to solve the proposed GNRPCA model. Finally, the proposed algorithm was used for video foreground-background separation. Simulation experiments were conducted, the experiment results were analyzed. The experiment results prove that the average F -measure value of the proposed algorithm is 0.589 2, which is 13% higher than the truncated nuclear norm algorithm. And the proposed algorithm is more superior and effective than other video foreground-background separation algorithms based on robust principal component analysis.

Keywords: robust principal component analysis; generalized nuclear norm; generalized norm; alternating direction method of multiplier (ADMM); video foreground-background separation

收稿日期: 2019-08-26 Received Date: 2019-08-26

^{*} 基金项目: 南京信息职业技术学院校级基金(YK20190402)、江苏省高校自然科学基金面上项目(19KJB510044)、国家自然科学基金(61501251)、中国博士后科学基金(2018M632326)、通信与网络技术国家工程研究中心开放课题(TXKY17010)、2019年度江苏省高等学校大学生创新创业训练计划项目(创新类项目)(201913112012Y)、江苏省第五期“333”高层次人才培养工程科研资助(BRA2019303)、2019年度江苏省高校“青蓝工程”优秀教学团队(苏教师[2019]3号)项目资助

0 引言

视频前背景分离技术^[1]是视频处理的基础和重要环节,是计算机视觉、运动目标检测识别^[2-3]和人体姿态跟踪^[4]等领域的重要研究对象。传统的视频前背景分离技术主要是对单个像素进行处理,例如高斯混合模型^[5]、ViBe 算法^[6]等,往往忽略视频像素之间以及帧与帧之间的相关性。主成分分析(principal component analysis, PCA)算法^[7]作为数据分析的主要工具被广泛用于视频背景建模,被证明是很好的降维工具^[8],然而,该算法难以直接精确提取运动的前景和处理腐蚀大的视频。

为了增强 PCA 算法的鲁棒性,鲁棒主成分分析(robust principal component analysis, RPCA)^[9-15]被提出并广泛用于视频前背景分离。视频背景的帧与帧之间具有强相关性,满足低秩特性,视频前景仅占视频很少一部分,满足稀疏特性,传统 RPCA 将观测视频矩阵分解为秩函数和 l_0 范数,即完成视频的背景建模和前景检测。传统 RPCA 模型可以通过对观测视频矩阵进行低秩稀疏分解来获取视频的低秩部分和稀疏部分。由于秩函数和 l_0 范数的非连续、非凸等特点,在求解的过程中需要穷举,即传统 RPCA 问题是 NP-难问题,一般难以求解。

为了求解传统 RPCA 问题,一般采用对该问题进行凸松弛近似的方法,从而提出了主成分追踪(principal component pursuit, PCP)算法^[12],该算法分别采用核范数和 l_1 范数去近似替代 RPCA 模型中的秩函数和 l_0 范数。研究表明,PCP 算法能较好地处理腐蚀严重的视频并实现简单场景视频的前背景分离。

近年来,PCP 算法凭借其易求解等优势成为研究的热点,但研究过程中发现几个重要缺陷^[12]。首先,由于某些视频具有不连续性,导致观测矩阵背景的低秩性不强,使得到的最优解产生偏差,导致分离的数据严重失真;其次,核范数是矩阵奇异值的 l_1 范数,在计算过程中会同等对待所有奇异值,进而出现对某些奇异值过惩罚的问题;最后,核范数本质是秩函数的凸闭包,这种近似替代是个有偏估计。

针对 PCP 算法的上述缺陷,研究者一直在寻找更理想的代理函数来逼近秩函数。近年来,许多国内外专家陆续提出了多种改进的算法^[16-22]。例如,文献[21]提出的去分解(go decomposition, GoDec)算法认为观测矩阵是由前景、背景和噪声组成,同时使用了双边随机投影(bilateral random projections, BRP)算法加速视频前背景分离算法。该算法虽然在一定程度上加快了视频前背景分离的速度,但是存在难于选择合适参数和对秩、稀疏度范围的约束导致的对属性的约束的缺陷。文献[22]基于较大奇异值并不影响矩阵奇异值个数的前提,提出了

截断核范数(truncated nuclear norm, TNN)算法,该算法采用 TNN 来替代 PCP 算法中的核范数,理论上 TNN 比核范数更逼近 RPCA 模型的秩函数,但该算法依赖于奇异值的选择策略以及决策过程中所使用的阈值参数,这一特性使得该算法不能广泛适应于所有场景,在某些场景下,TNN 算法的效果甚至不如 PCP 算法。

由于基于非凸代理函数的算法比基于凸代理函数的算法更加逼近秩函数和稀疏度,并能取得了更好的性能,人们逐渐将研究重点从易于求解的凸松弛问题转移到基于非凸函数近似逼近问题^[23-32]。文献[23-25]提出利用非凸非光滑加权核范数(nonconvex nonsmooth weighted nuclear norm, NNWNN)来近似逼近秩函数,以期达到更好的逼近效果,该算法凭借可以针对不同奇异值进行不同惩罚的机制提高了视频前背景分离的效果。为了进一步改进算法的前背景分离效果,文献[26]采用广义奇异阈值算子代替奇异值阈值算子求解秩最小化问题,提出了非凸低秩稀疏分解(nonconvex low-rank and sparse decomposition, NonLRSD)算法,该算法在一定程度上提高了视频前背景分离的效果。文献[27-28]提出了一种基于自适应正则化学习的低秩(adaptive regularizer learning for low rank, ARLLR)近似算法,该算法借助于最大后验概率,采用自适应的正则化算子替代 PCP 算法的 l_1 范数,该算法被应用于图像去噪和视频前背景分离并取得了较好的效果。虽然上述非凸代理函数的 RPCA 算法较凸代理函数逼近度更高^[29-32],但是这些算法只是采用非凸代理函数逼近观测矩阵的秩函数或稀疏度,并没有采用统一的非凸代理函数同时逼近秩函数和稀疏度函数,所以有待提出更精确、形式更一般的 RPCA 逼近模型。

本文提出了一种基于广义非凸鲁棒主成分分析(generalized nonconvex robust principal component analysis, GNRPCA)的视频前背景分离算法。该算法采用非凸广义核范数(generalized nuclear norm, GNN)逼近秩函数,是秩函数的一个无偏估计。它区别对待低秩矩阵的各个不同奇异值,与核范数、截断核范数相比能更好地逼近秩函数,更精确提取视频中具有低秩特征的背景。另外,该算法为了更好地逼近稀疏度,同时引入了非凸广义范数(generalized norm, GN)近似替代具有表示稀疏先验的 l_0 范数,比 l_1 范数更逼近矩阵的稀疏度。本文提出的 GNN 和 GN 分别是秩函数和 l_0 范数的更精确的非凸逼近形式,分别能更好地近似 RPCA 模型中的低秩矩阵和稀疏矩阵。此外,本文还采用交替方向乘子法(alternating direction method of multipliers, ADMM)^[33-36]对提出的模型进行求解。最后,对提出的 GNRPCA 算法进行视频前背景分离仿真实验,实验结果表明了本文算法的有效性和优越性。

1 广义非凸鲁棒主成分分析

1.1 广义非凸鲁棒主成分分析模型

虽然凸优化问题计算简单且易于实现,但凸代理函数对 RPCA 模型中的秩函数和 l_0 范数的逼近是有偏估计,逼近效果不佳。所以,人们提出采用非凸代理函数来逼近传统 RPCA 模型中的秩函数或稀疏度函数的方法。研究表明基于非凸代理函数的 RPCA 模型优于基于凸函数的近似替代模型^[23-32]。

当非凸函数 $g(\cdot)$ 是闭的、正常的下半连续函数时,广义非凸函数 $\sum_i g(\sigma_i(L))$ 和 $\sum_j g(|S_j|)$ (其中 $i = 1, 2, \dots, \min(m, n); j = 1, 2, \dots, mn$) 分别是秩函数和稀疏度函数的更精确、形式更一般的逼近函数,称这两个广义非凸代理函数分别为广义核范数和广义范数。本文采用广义核范数替代传统 RPCA 模型中的低秩部分即秩函数部分,同时采用广义范数来替代传统 RPCA 模型中的稀疏部分即 l_0 范数部分,提出如下的形式更一般的广义非凸鲁棒主成分分析模型:

$$\min_{L, S} \tau \sum_i g(\sigma_i(L)) + \lambda \sum_j g(|S_j|) \quad (1)$$

$$\text{s.t. } D = L + S$$

式中: $g(\cdot): \mathbb{R}^+ \rightarrow \mathbb{R}^+$ 是非凸的、闭的、正常的下半连续函数; $\sigma_i(L)$ 为低秩矩阵 L 的第 i 个奇异值; S_j 为稀疏矩阵 S 的第 j 个元素; $\lambda, \tau > 0$ 均为参数。提出的广义非凸鲁棒主成分分析模型是传统 RPCA 模型的更一般、更精确的逼近形式。当非凸函数 $g(\cdot)$ 是 Logarithm 函数时,有 $g(x) = \frac{\log(\gamma x + 1)}{\log(\gamma + 1)}$, 其中 $\gamma > 0$ 为参数。于是有:

$$\lim_{\gamma \rightarrow \infty} g(x) = \lim_{\gamma \rightarrow \infty} \frac{\log(\gamma x + 1)}{\log(\gamma + 1)} = \lim_{\gamma \rightarrow \infty} \frac{x \left(1 + \frac{1}{\gamma}\right)}{x + \frac{1}{\gamma}} = 1 \quad (2)$$

$$\lim_{\gamma \rightarrow 0} g(x) = \lim_{\gamma \rightarrow 0} \frac{\log(\gamma x + 1)}{\log(\gamma + 1)} = \lim_{\gamma \rightarrow 0} \frac{\gamma x}{\gamma} = x \quad (3)$$

因此有:

$$\lim_{\gamma \rightarrow \infty} \sum_i g(\sigma_i(L)) = \text{rank}(L), \lim_{\gamma \rightarrow 0} \sum_i g(\sigma_i(L)) = \|L\|_* \quad (4)$$

$$\lim_{\gamma \rightarrow \infty} \sum_j g(|S_j|) = \|S\|_0, \lim_{\gamma \rightarrow 0} \sum_j g(|S_j|) = \|S\|_1 \quad (5)$$

所以广义核范数和广义范数分别是比 PCP 模型中的核范数和 l_1 范数更好的秩函数和 l_0 范数的近似逼近。当 γ 非常大时,广义核范数几乎和秩函数一致,广义范数几乎和 l_0 范数一致;当 γ 非常小时,广义核范数几乎和核范数一致,广义范数几乎和 l_1 范数一致。因此提出的广

义非凸鲁棒主成分分析模型(1)是比 PCP 模型更加精确的 RPCA 逼近模型,其性能更优。此外,该模型在求解的过程中不需要穷举,可以采用邻近算子进行求解,比传统 RPCA 模型更容易求解。广义收缩阈值算子是夹在软阈值收缩算子和硬阈值收缩算子之间的邻近算子,可以有效改善软阈值的有偏问题以及硬阈值的不稳定问题。最重要的是该模型是个广义 RPCA 模型,只要非凸函数 $g(\cdot)$ 满足闭的、正常的下半连续的性质,例如 Logarithm 惩罚函数、 $l_p - \text{norm}$ ($0 < p < 1$)、平滑切片绝对偏差惩罚函数(smoothly clipped absolute deviation, SCAD)、最小-最大非凸惩罚函数(minimax concave penalty, MCP)、Geman 惩罚函数、Laplace 惩罚函数等^[33-39]都可以看成是广义非凸代理函数,由这些广义非凸代理函数构建的模型均可以看成是提出的广义非凸鲁棒主成分分析模型的特例。值得一提的是当 $g(x) = x$ 时,广义核范数即为核范数,广义范数即为 l_1 范数,提出的 GNRPCA 模型则退化为 PCP 模型。

1.2 广义非凸鲁棒主成分分析算法

本文采用交替方向乘子法(ADMM)^[33-36]对提出的广义非凸鲁棒主成分分析模型进行求解。

GNRPCA 问题(1)对应的增广拉格朗日函数为:

$$(L, S, Y, \mu) = \tau \sum_i g(\sigma_i(L)) + \lambda \sum_j g(|S_j|) - \langle Y, L + S - D \rangle + \frac{\mu}{2} \|L + S - D\|_F^2 \quad (6)$$

式中: $\mu > 0$ 是惩罚因子; Y 是拉格朗日乘子; $\langle \cdot, \cdot \rangle$ 为矩阵的内积。

首先,固定 S, Y 和 μ ,更新 L , 于是有:

$$L^{k+1} = \argmin_L \tau \sum_i g(\sigma_i(L)) - \langle Y^k, L + S^k - D \rangle + \frac{\mu_k}{2} \|L + S^k - D\|_F^2 = \argmin_L \frac{\tau}{\mu_k} \sum_i g(\sigma_i(L)) + \frac{1}{2} \|L - \left(D - S^k + \frac{Y^k}{\mu_k}\right)\|_F^2 \quad (7)$$

采用广义奇异值阈值(generalized singular value thresholding, GSVT)算子 $\text{prox}_{\frac{\tau}{\mu_k}}^g(\cdot)$ ^[26,32-33] 对其进行求解得:

$$L^{k+1} = \text{prox}_{\frac{\tau}{\mu_k}}^g\left(D - S^k + \frac{Y^k}{\mu_k}\right) = U^k \text{Diag}\left(\text{prox}_{\frac{\tau}{\mu_k}}^g\left(\sigma_i\left(D - S^k + \frac{Y^k}{\mu_k}\right)\right)\right) (V^k)^T \quad (8)$$

式中: U^k 和 V^k 由对矩阵 $D - S^k + Y^k/\mu_k$ 进行奇异值分解; $\text{Diag}(\cdot)$ 为矩阵对应的对角阵; $\text{prox}_{\frac{\tau}{\mu_k}}^g(\cdot)$ 为非凸函数 $g(\cdot)$ 的邻近算子^[26,35-37],其标量表达格式如式(9)所示。

$$\text{prox}_{\frac{\tau}{\mu_k}}^g\left(\sigma_i\left(D - S^k + \frac{Y^k}{\mu_k}\right)\right) =$$

$$\operatorname{argmin}_{\tau \geq 0} \frac{\tau}{\mu_k} g(l) + \frac{1}{2} \left(l - \sigma_i \left(\mathbf{D} - \mathbf{S}^k + \frac{\mathbf{Y}^k}{\mu_k} \right) \right)^2 \quad (9)$$

然后,固定 $\mathbf{L}, \mathbf{Y}$ 和 μ ,更新 $\mathbf{S}$, 于是得到:

$$\mathbf{S}^{k+1} = \operatorname{argmin}_{\mathbf{S}} \lambda \sum_j g(|S_j|) - \langle \mathbf{Y}, \mathbf{L}^{k+1} + \mathbf{S} - \mathbf{D} \rangle +$$

$$\frac{\mu_k}{2} \|\mathbf{L}^{k+1} + \mathbf{S} - \mathbf{D}\|_F^2 = \operatorname{argmin}_{\mathbf{S}} \frac{\lambda}{\mu_k} \sum_j g(|S_j|) + \frac{1}{2} \|\mathbf{S} - \left(\mathbf{D} - \mathbf{L}^{k+1} + \frac{\mathbf{Y}^k}{\mu_k} \right)\|_F^2 \quad (10)$$

由邻近算子的定义可以得到:

$$\mathbf{S}^{k+1} = \operatorname{prox}_{\frac{\lambda}{\mu_k}} \left(\mathbf{D} - \mathbf{L}^{k+1} + \frac{\mathbf{Y}^k}{\mu_k} \right) \quad (11)$$

最后,分别对乘子 $\mathbf{Y}$ 和惩罚参数 μ 进行更新:

$$\mathbf{Y}^{k+1} = \mathbf{Y}^k - \mu_k (\mathbf{L}^{k+1} + \mathbf{S}^{k+1} - \mathbf{D}) \quad (12)$$

$$\mu_{k+1} = \min(\rho \mu_k, \mu_{\max}) \quad (13)$$

式中: $\rho > 1$ 为放大因子。

综上所述,采用 ADMM 算法求解提出的 GNRPCA 模型(1)的具体步骤如下。

1) 初始化,给定 $\lambda > 0, \mu_0 > 0, \mu_{\max} > \mu_0$ 和 $\rho > 1$,

初始点 $\mathbf{L}_0 = \mathbf{0}, \mathbf{S}_0 = \mathbf{0}$ 和 $\mathbf{Y}_0 = \frac{\mathbf{D}}{\max(\|\mathbf{D}\|_2, \sqrt{mn} \|\mathbf{D}\|_\infty)}$,迭

代次数 $k = 0$;

2) 更新变量 $\mathbf{L}$,根据式(8)更新变量 $\mathbf{L}^{k+1}$;

3) 更新变量 $\mathbf{S}$,根据式(11)更新变量 $\mathbf{S}^{k+1}$;

4) 更新变量 $\mathbf{Y}$,根据式(12)更新变量 $\mathbf{Y}^{k+1}$;

5) 更新变量 μ ,根据式(13)更新变量 μ_{k+1} ;

6) 若满足终止条件 $\frac{\|\mathbf{D} - \mathbf{L}^{k+1} - \mathbf{S}^{k+1}\|_F}{\|\mathbf{D}\|_F} \leq 10^{-4}$,则

迭代终止,否则,令 $k = k + 1$ 返回步骤 2)。

2 实验结果及分析

为了验证本文提出的广义非凸鲁棒主成分分析算法在视频前背景分离中的优越性和有效性。本文以 CDnet 数据集^[40]提供的 11 个视频作为试验对象,选取各视频的连续 100 帧进行仿真实验,11 个视频分别为: Blizzard、Canoe、Highway、Office、Pets、Skating、SnowBall、BackDoor、BusStation、Cubicle、Corridor。另外,为了测试提出算法的实际应用效果,本文还采用 6 个实际应用场景的视频作为试验对象,包括超市、学校、地铁站、机场和室内办公场景的 6 个视频,分别为: ShoppingMall、Campus、Escalator、Fountain、Airport、Lobby。同时,为了凸显提出的 GNRPCA 算法的优势,实验以 NonLRSD、Godec、TNN、NNWNN 和 PCP 算法作为对比算法,并使用上述算法对不同视频进行仿真实验,并对实验结果进行比较和分析。

本文为了定量评价算法的优劣,采用 F -measure 值对

不同算法的视频前背景分离的效果进行量化评价。 F -measure 值是用来衡量视频前背景分离效果的定量指标,其表达式如下:

$$F = \frac{2rp}{r + p} \quad (14)$$

式中: $p = \frac{TP}{TP + FP}$ 为准确率;用于衡量查准率, $r =$

$\frac{TP}{TP + FN}$ 为召回率,用于衡量查全率; TP 是判断为前景

的正确像素的个数; FP 是判断为背景的错误像素的个数; FN 为将前景错判为背景的像素的个数。 F -measure 值介于 0~1,数值越大,表明视频前背景分离的效果越好。

GNRPCA 算法的参数设置为 $\rho = 1.5, \mu = \frac{1.25}{\|\mathbf{D}\|_2}$ 、

$\mu_{\max} = 10^7, \lambda = \frac{1}{\sqrt{\max(m, n)}}$,其中, m, n 分别为矩阵 $\mathbf{D}$ 的

行和列数,由于 τ 取值范围较大,为了便于调整参数 τ 的值,实验中设置 τ 的值为 $\tau = C \|\operatorname{vec}(\mathbf{D})\|_\infty$,通过调整参数 C 来调整参数 τ 的值,其中, $\operatorname{vec}(\mathbf{D})$ 表示对矩阵 $\mathbf{D}$ 进行向量化。经过试验验证当 $C = 181, \gamma = 1$ 时本文提出算法性能最好。

由于 GNRPCA 模型中的广义非凸代理函数 $g(\cdot): \mathbf{R}^+ \rightarrow \mathbf{R}^+$ 只要满足非凸的、闭的、正常的下半连续即可,满足这样的惩罚函数有很多,例如 Logarithm 惩罚函数、 lp -norm ($0 < p < 1$)、SCAD 惩罚函数、MCP 惩罚函数、Geman 惩罚函数、Laplace 惩罚函数等。为了选取最优的非凸惩罚函数,在其他条件相同的情况下,采用不同非凸惩罚函数对视频进行前背景分离,本文以 Highway 视频为例展示基于各种不同非凸惩罚函数的视频前背景分离的效果,其 F -measure 值如表 1 所示。

表 1 不同惩罚函数的 F -measure 值

Table 1 The F -measure values for different penalty functions

非凸惩罚函数	F -measure 值
Logarithm	0.750 2
lp -norm	0.731 2
SCAD	0.735 1
MCP	0.690 1
Geman	0.748 5
Laplace	0.696 1

从表 1 可以看出,与其他非凸惩罚函数相比,Logarithm 惩罚函数进行视频前背景分离的 F -measure 值最大,所以本文选用效果较好的 Logarithm 惩罚函数^[37]作为 GNRPCA 模型的非凸替代函数。

为了说明提出的 GNRPCA 算法的优越性和有效性,本文随机选取 CDnet 数据集的 11 个实验视频和 6 个实际应用场景视频的其中一帧,实验结果分别如图 1 和 2 所示。

图 1 和 2 所示分别为 CDnet 数据集的 11 个视频和实际应用场景的 6 个视频的实验效果,其中 (a) 为原始视频帧,(b) 为选取帧的真实前景,(c)~(h) 分别为 GNRPCA、NonLRSD、Godec、TNN、NNWNN 和 PCP 算法提取的前景。由图 1 和 2 可以看出,GNRPCA 算法对

各实验视频提取的前景信息更加丰富,轮廓更加完整,误采样现象相对较少,例如,GNRPCA 算法对 Skating 视频的前景人提取的信息更加充分,提取的身体部分相对较多;对 Office 视频中前景人的轮廓提取相对完整,尤其对头部信息的描述更加接近实际轮廓;对 BackDoor 视频中背景误采样为前景的像素较少;对 Lobby 视频提取的前景人身体的信息更加丰富,对 ShoppingMall 前景人的轮廓提取的更加完整,对 Campus 前景人的误采样现象较少。




图 1 CDnet 视频前景提取实验对比

Fig.1 Comparison of the video foreground extraction experiments for CDnet

综上所述,本文提出的 GNRPCA 算法对 CDnet 数据集中视频和实际应用场景的视频提取的前景具有更好的信息丰富性、轮廓完整性,并且误采样情况较少,从而从视觉角度验证了本文提出的 GNRPCA 算法的优越性和有效性,同时通过对实际应用场景视频的效果展示也说明了本文提出的 GNRPCA 算法具有较好的实际应用

效果。为了定量说明 GNRPCA 算法的优越性和有效性,实验还分别给出不同算法的 CDnet 数据集的 11 个视频和实际应用场景的 6 个视频前背景分离效果的 F -measure 值,分别如表 2 和 3 所示。从表 2 可以看出本文提出的 GNRPCA 算法对各个




图 2 实际应用场景视频前景提取实验对比

Fig.2 Comparison of the video foreground extraction experiments in actual application scenarios

表 2 各个算法对 CDnet 视频处理的 F -measure 值

Table 2 The F -measure values of different algorithms in CDnet video processing

实验对象	GNRPCA	NonLRSD	Godec	TNN	NNWNN	PCP
Blizzard	0.730 9	0.709 2	0.671 0	0.524 8	0.687 4	0.664 8
Canoe	0.346 4	0.306 2	0.304 1	0.202 2	0.296 5	0.235 9
Highway	0.750 2	0.717 2	0.708 3	0.584 2	0.620 4	0.516 1
Office	0.683 5	0.512 8	0.585 4	0.411 7	0.495 2	0.484 2
Pets	0.612 8	0.539 4	0.517 6	0.480 1	0.539 5	0.536 8
Skating	0.629 6	0.579 2	0.561 3	0.400 5	0.590 9	0.510 9
SnowFall	0.701 5	0.650 0	0.537 3	0.480 8	0.502 8	0.542 8
BackDoor	0.640 3	0.614 9	0.558 2	0.559 4	0.579 9	0.539 7
BusStation	0.570 2	0.568 8	0.559 4	0.522 8	0.540 8	0.530 2
Cubicle	0.539 5	0.500 4	0.347 2	0.174 9	0.531 3	0.426 9
Corridor	0.526 2	0.503 9	0.521 5	0.384 4	0.477 7	0.420 9

视频前背景分离得到的 F -measure 值高于表中其他算法,例如,GNRPCA 算法对 Highway 视频前背景分离的 F -measure 值为 0.750 2,比 NNWNN 高 0.13,比 PCP 算法高 0.24;GNRPCA 算法对 Office 视频前背景分离的 F -measure 值为 0.683 5,比 NonLRSD 算法高 0.17;GNRPCA 算法对 Skating 视频前背景分离的 F -measure 值为 0.629 6,比 TNN 算法高 0.22;GNRPCA 算法对 Cubicle 视频前背景分离的 F -measure 值为 0.539 5,比

表 3 各个算法对实际应用场景视频处理的 F -measure 值

Table 3 The F -measure values of different algorithms in actual application scenarios

实验对象	GNRPCA	NonLRSD	Godec	TNN	NNWNN	PCP
Shopping-Mall	0.591 3	0.584 7	0.582 2	0.577 1	0.585 7	0.568 5
Campus	0.324 4	0.299 0	0.200 3	0.244 6	0.287 4	0.254 0
Escalator	0.565 7	0.559 1	0.530 1	0.540 4	0.556 0	0.541 7
Fountain	0.653 4	0.631 0	0.428 3	0.640 9	0.650 8	0.599 7
airport	0.606 1	0.577 9	0.594 3	0.560 2	0.559 8	0.538 3
Lobby	0.543 8	0.537 3	0.496 4	0.498 3	0.534 0	0.477 0

Godec 算法高 0.19,比 TNN 算法高 0.36。GNRPCA 算法对 Lobby 视频前背景分离的 F -measure 值为 0.543 8,比 PCP 高 0.07。

综上所述,本文提出的 GNRPCA 算法的视频前背景分离效果优于其他基于 RPCA 视频前背景分离算法,这也与图 1 和 2 的视觉效果一致。同时,由表 3 的实际应用场景视频的 F -measure 值的实验结果,也说明了本文提出的 GNRPCA 算法具有较好的实际应用效果。

为了说明 GNRPCA 算法时间复杂度的优越性,实验分别统计了不同算法对各实验视频进行前背景分离的时间,如表 4 和 5 所示,其中表 4 所示为各个算法对 CDnet 视频处理的运行时间比较,表 5 所示为各个算法对实际

应用场景视频处理的运行时间比较。从表 4 和 5 可以看出,无论是 CDnet 视频,还是实际应用场景视频,本文提出的算法进行视频前背景分离的运行时间小于 NonLRSD、TNN、NNWNN 和 PCP 算法的运行时间,具有较低的时间复杂度,例如表 4 中,GNRPCA 算法对 Pets 视频的每一帧的平均处理时间为 0.444 7 s,比 TNN 算法快 0.9 s 左右;表 5 中 GNRPCA 算法对 Campus 视频的每一帧的平均处理时间为 0.010 8 s,比 TNN 算法快 0.03 s 左右。

表 4 各个算法对 CDnet 视频处理的每帧运行时间比较

Table 4 Comparison of the running time per frame of different algorithms in CDnet video processing (s)

实验对象	GNRPCA	NonLRSD	Codec	TNN	NNWNN	PCP
Blizzard	0.514 0	1.133 7	0.074 1	1.535 8	0.919 9	1.206 5
Canoe	0.070 0	0.235 8	0.013 8	0.306 1	0.187 7	0.291 9
Highway	0.067 6	0.214 5	0.013 7	0.280 5	0.185 2	0.242 5
Office	0.174 8	0.230 2	0.251 2	0.563 0	0.202 9	0.266 2
Pets	0.444 7	1.079 0	0.085 2	1.361 5	0.947 7	1.130 1
Skating	0.262 9	0.657 4	0.039 4	0.837 1	0.608 4	0.666 1
SnowBall	0.510 5	0.980 5	0.075 7	1.399 4	0.902 1	1.231 7
Backdoor	0.182 0	0.208 8	0.104 5	0.283 3	0.204 4	0.229 7
BusStation	0.100 7	0.329 7	0.023 5	0.330 6	0.313 4	0.268 2
Cubicle	0.106 0	0.347 5	0.029 1	0.368 2	0.248 3	0.306 3
Corridor	0.096 0	0.214 6	0.054 9	0.336 3	0.240 8	0.245 9

表 5 各个算法对实际应用场景视频处理的每帧运行时间比较

Table 5 Comparison of the running time of different algorithms in actual application scenarios (s)

实验对象	GNRPCA	NonLRSD	Codec	TNN	NNWNN	PCP
Shopping-Mall	0.015 1	0.026 2	0.003 3	0.044 3	0.033 6	0.034 4
Campus	0.010 8	0.042 5	0.003 5	0.047 2	0.041 0	0.032 1
Escalator	0.028 7	0.039 8	0.003 4	0.041 5	0.033 2	0.035 0
Fountain	0.018 7	0.036 6	0.003 5	0.049 3	0.033 8	0.032 5
Airport	0.029 7	0.042 3	0.004 7	0.075 6	0.033 0	0.041 3
Lobby	0.018 5	0.030 9	0.002 9	0.041 4	0.033 5	0.033 3

综合考虑视频前背景分离的效果和运行时间,可以得出本文提出的 GNRPCA 算法比 NonLRSD、Codec、TNN、NNWNN 和 PCP 算法更有优越性和有效性。

3 结 论

本文针对基于传统鲁棒主成分分析的视频前背景分

离算法精度不高的问题,提出了一种基于广义非凸鲁棒主成分分析的视频前背景分离算法,该算法分别采用广义核范数和广义范数来替代鲁棒主成分分析模型中的低秩部分和稀疏部分,相比其他基于鲁棒主成分分析的视频前背景分离算法更能逼近视频低秩的背景部分和稀疏的前景部分。此外,将提出的基于广义非凸鲁棒主成分分析方法用于视频前背景分离,进行仿真实验并对实验结果进行了分析。实验结果表明,提出的 GNRPCA 算法比其他 RPCA 算法具有更好的前景提取效果和更少的时间复杂度,更具有优越性和有效性。在后续的研究中,将引入低秩和稀疏部分的结构化信息,以期进一步提高视频前背景分离的效果。

参考文献

[1] BOUWMANS T, SOBRAL A, JAVED S, et al. Decomposition into low-rank plus additive matrices for background/foreground separation: A review for a comparative evaluation with a large-scale dataset[J]. Computer Science Review, 2017(23):1-71.

[2] 李成美,白宏阳,郭宏伟,等. 一种改进光流法的运动目标检测及跟踪算法[J]. 仪器仪表学报, 2018, 39(5): 249-256.

LI CH M, BAI H Y, GUO H W, et al. Moving object detection and tracking based on improved optical flow method[J]. Chinese Journal of Scientific Instrument, 2018,39(5):249-256.

[3] 蔡德饶,张婷. 联合多分辨表示的 SAR 图像目标识别方法[J]. 电子测量与仪器学报, 2018, 32(12): 76-82.

CAI D R, ZHANG T. SAR target recognition based on joint use of multi-resolution representations[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(12):76-82.

[4] TIAN J L, WANG ZH Y, LI L, et al. Tracking human poses with head orientation estimation[J]. Instrumentation, 2017, 4(3):40-46.

[5] SHI G, HUANG T, DONG W, et al. Robust foreground estimation via structured gaussian scale mixture modeling[J]. IEEE Transactions on Image Processing, 2018, 27(10):4810-4824.

[6] BARNICH O, DROOGENBROECK M V. ViBe: A universal background subtraction algorithm for video sequences[J]. IEEE Transactions on Image Processing, 2011, 20(6):1709-1724.

[7] OLIVER N M, ROSARIO B, PENTLAND A P. A Bayesian computer vision system for modeling human interactions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8):831-843.

- [8] STIEF A, OTTEWILL J, BARANOWSKI J, et al. A PCA-two stage Bayesian sensor fusion approach for diagnosing electrical and mechanical faults in induction motors[J]. IEEE Transactions on Industrial Electronics, 2019, 66(12):9510-9520.
- [9] CANDÉS E, LI X D, YU L, et al. Robust principal component analysis: recovering low-rank matrices from sparse errors[C]. IEEE Sensor Array and Multichannel Signal Processing Workshop, 2010, DOI: 10.1109/SAM.2010.5606734.
- [10] WEN F, YING R D, LIU P L, et al. Robust PCA using generalized nonconvex regularization[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019: 1-14.
- [11] PENG Y, GANESH A, WRIGHT J, et al. RASL: Robust alignment by sparse and low-rank decomposition for linearly correlated images[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 34(11): 2233-2246.
- [12] BOUWMANS T, ZAHZAH E H. Robust PCA via principal component pursuit: A review for a comparative evaluation in video surveillance[J]. Computer Vision and Image Understanding, 2014(122):22-34.
- [13] LU C Y, FENG J SH, CHEN Y D, et al. Tensor robust principal component analysis with a new tensor nuclear norm[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018:1-9.
- [14] WRIGHT J, PENG Y, MA Y, et al. Robust principal component analysis: Exact recovery of corrupted low-rank matrices by convex optimization[J]. Advances in Neural Information Processing Systems (NIPS), 2009:1-9.
- [15] CANDS E J, LI X D, MA Y, et al. Robust principal component analysis? [J]. Journal of the ACM, 2011, 58(3):1-37.
- [16] 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.
- [17] YE X CH, YANG J Y, SUN X, et al. Foreground-background separation from video clips via motion-assisted matrix restoration[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2015, 25(11):1721-1734.
- [18] ZHOU X W, YANG C, YU W CH. 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.
- [19] CAO X CH, 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.
- [20] 杨真真, 范露, 杨永鹏, 等. 改进的低秩稀疏分解及其在目标检测中的应用[J]. 仪器仪表学报, 2019, 40(4): 198-206.
- YANG ZH ZH, FAN L, YANG Y P, et al. Improved low-rank and sparse decomposition with application to object detection[J]. Chinese Journal of Scientific Instrument, 2019, 40(4): 198-206.
- [21] ZHOU T, TAO D. GoDec: Randomized low-rank & sparse matrix decomposition in noisy case[C]. International Conference on Machine Learning, 2011:33-40.
- [22] HU Y, ZHANG D B, YE J P, et al. Fast and accurate matrix completion via truncated nuclear norm regularization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(9):2117-2130.
- [23] YANG ZH ZH, YANG ZH, HAN D R. Alternating direction method of multipliers for sparse and low-rank decomposition based on nonconvex nonsmooth weighted nuclear norm[J]. IEEE Access, 2018, 6(1): 56945-56953.
- [24] GU SH H, XIE Q, MENG D Y, et al. Weighted nuclear norm minimization and its applications to low level vision[J]. International Journal of Computer Vision, 2017, 121(2):183-208.
- [25] GU SH H, ZHANG L, ZUO W M, et al. Weighted nuclear norm minimization with applications to image denoising[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 2862-2869.
- [26] YANG ZH ZH, FAN L, YANG Y P, et al. Generalized singular value thresholding operator based nonconvex low-rank and sparse decomposition for moving object detection[J]. Journal of the Franklin Institute, 2019, 356(16): 10138-10154.
- [27] JIA X, FENG X, WANG W, et al. Adaptive regularizer learning for low rank approximation with application to image denoising[C]. IEEE International Conference on Image Processing (ICIP), 2016: 3096-3100.
- [28] JIA X, FENG X, WANG W, et al. Bayesian inference for adaptive low rank and sparse matrix estimation[J]. Neurocomputing, 2018, 291, 71-83.
- [29] XU F, HAN J Q, WANG Y L, et al. Dynamic magnetic resonance imaging via nonconvex low-rank matrix approximation[J]. IEEE Access, 2017(5):1958-1966.
- [30] YANG L, PONG T K, CHEN X. Alternating direction method of multipliers for a class of nonconvex and

- nonsmooth problems with applications to background/foreground extraction [J]. SIAM Journal on Imaging Sciences, 2017, 10(1):74-110.
- [31] LI Q W, TANG G G. The nonconvex geometry of low-rank matrix optimizations with general objective functions[C]. Signal & Information Processing, 2018: 1235-1239.
- [32] LI Y Y, LIN Y, CHENG X F, et al. Nonconvex penalized regularization for robust sparse recovery in the presence of impulsive noises[J]. IEEE Access, 2018, 6(1):25474-25485.
- [33] YUAN X M, YANG J F. Sparse and low rank matrix decomposition via alternating direction method [J]. Pacific Journal of Optimization, 2013, 9(1):1-11.
- [34] YANG ZH ZH, YANG ZH. Fast linearized alternating direction method of multipliers for the augmented l_1 -regularized problem [J]. Signal Image & Video Processing, 2015, 9(7): 1601-1612.
- [35] YANG L, PONG T K, CHEN X J. Alternating direction method of multipliers for a class of nonconvex and nonsmooth problems with applications to background/foreground extraction [J]. SIAM Journal on Imaging Sciences, 2017, 10(1):74-110.
- [36] WEN F, YING R D, LIU P L, et al. Robust PCA using generalized nonconvex regularization [C]. IEEE Transactions on Circuits and Systems for Video Technology, 2019:1-14.
- [37] LU C Y, ZHU CH B, XU CH Y, et al. Generalized singular value thresholding [C]. Twenty-Ninth AAAI Conference on Artificial Intelligence, . 2015:1805-1811.
- [38] LU C Y, TANG J H, YAN SH CH, et al. Generalized nonconvex nonsmooth low-rank minimization [C]. The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014: 4130-4137.
- [39] LU C Y, TANG J H, YAN SH CH, et al. Nonconvex nonsmooth low-rank minimization via iteratively reweighted nuclear norm [J]. IEEE Transactions on Image Process, 2016, 25(2):829-839.
- [40] LI L Y, HUANG W M, GU I Y H, et al. Statistical modeling of complex backgrounds for foreground object detection[J]. IEEE Transactions on Image Processing, 2004, 13(11):1459-1472.

作者简介



杨永鹏 (通信作者), 2008 年于临沂大学获得学士学位, 2011 年于南京邮电大学获得硕士学位, 现为南京信息职业技术学院讲师, 主要研究方向为低秩稀疏分解、多媒体信息处理。

E-mail: yangyp@njcit.cn

Yang Yongpeng (Corresponding author) received his B. Sc. degree from Linyi University in 2008, and received his M. Sc. degree from Nanjing University of Posts and Telecommunications in 2011. Now, he is a lecturer at Nanjing Vocational College of Information Technology. His main research interests include low-rank and sparse decomposition and multimedia information processing.



杨真真, 2008 年于临沂大学获得学士学位, 分别在 2011 年和 2014 年于南京邮电大学获得硕士学位和博士学位, 现为南京邮电大学副教授, 主要研究方向为低秩稀疏分解、多媒体信息处理。

E-mail: yangzz@njupt.edu.cn

Yang Zhenzhen received her B. Sc. degree from Linyi University in 2008, and received her M. Sc. and Ph. D. degrees both from Nanjing University of Posts and Telecommunications in 2011 and 2014, respectively. Now, she is an associate professor at Nanjing University of Posts and Telecommunications. Her main research interest includes low-rank and sparse decomposition, and multimedia information processing.