

文章编号: 2095-4980(2020)05-0883-07

一种改进的在线图像对齐算法

陈 平, 杜 恒

(河南工业职业技术学院 电子信息工程系, 河南 南阳 470000)

摘 要: 由于图像之间存在光照变化巨大、部分遮挡和损坏等现象, 稳健且高效的图像对齐仍然是一项具有挑战性的任务。为此, 提出了一种改进的在线图像对齐算法。通过图像梯度方向(IGO)的主成分分析(PCA)来提供比像素强度更可靠的低维子空间, 然后在 IGO 域中寻找对齐, 使新到达图像的 IGO 对齐被分解为稀疏误差和从先前良好对齐图像上学习得到的 IGO-PCA 基的线性组合的总和, 进而图像对齐问题可被建模为 l_1 范数最小化问题。将该问题松弛为凸优化问题, 并提出一种基于乘子交替方向法的凸优化求解算法。考虑 IGO 均值的偏移, 基于增量奇异值分解自适应地更新 IGO-PCA 基。在大量具有挑战性的数据集上验证了所提算法的有效性。实验结果表明, 相比于目前典型的尺度不变特征变换(SIFT)算法、稀疏和低秩分解(RASL)算法和变换 Grassmannian 鲁棒自适应子空间跟踪算法(t-GRASTA), 本文算法的对齐效果更佳, 对于图像的光照变化和遮挡现象等具有更强的鲁棒性。

关键词: 图像对齐; 梯度方向; 凸优化; 奇异值分解; 鲁棒性

中图分类号: TN911.73

文献标志码: A

doi: 10.11805/TKYDA2019093

An improved online image alignment algorithm

CHEN Ping, DU Heng

(Department of Electric and Information Engineering, Henan Polytechnic Institute, Nanyang Henan 470000, China)

Abstract: Due to the phenomena of huge illumination changes, partial occlusion and damage between images, robust and efficient image alignment is still a challenging task. An improved online image alignment algorithm is proposed. Firstly, the Principal Component Analysis(PCA) of image gradient orientations(IGO) is utilized to provide a lower dimensional subspace which is more reliable than the intensity of pixels. The alignment is sought in the IGO domain such that the aligned IGO of the newly arrived image can be decomposed as the sum of a sparse error and a linear composition of the IGO-PCA basis learned from previously well-aligned ones. The image alignment problem can be modeled as a norm minimization problem. The problem is relaxed to a convex optimization problem in this paper, and a convex optimization algorithm based on multiplier alternating direction method is proposed. IGO-PCA basis are adaptively updated based on incremental singular value decomposition considering the migration of IGO mean in this paper. The effectiveness of the proposed algorithm is validated on a large number of challenging data sets. The experimental results show that compared with the current typical SIFT algorithm, Robust Alignment by Sparse and Low-rank decomposition(RASL) algorithm and transformed Grassmannian Robust Adaptive Subspace Tracking Algorithm(t-GRASTA), the alignment effect of the proposed algorithm is the best, and it has the strongest robustness to illumination changes and occlusion phenomena of images.

Keywords: image alignment; gradient orientations; convex optimization; singular value decomposition; robustness

图像对齐^[1]是计算机视觉中使用最广泛的图像处理技术之一。该技术寻求最佳图像变换以建立不同图像之间的空间对应关系。在医学图像注册、图像识别和视觉追踪等领域都利用图像对齐来估计图像之间的对应关系。

收稿日期: 2019-03-18; 修回日期: 2019-06-28

基金项目: 国家自然科学基金面上资助项目(61401402)

作者简介: 陈 平(1972-), 男, 硕士, 副教授, 研究方向为图像处理、软件工程。email:hn_chenping1@163.com

近年来,随着 Facebook 和 Instagram 等社交网络中图像和视频共享的日益普及,在线可用的视觉数据量急剧增加。然而由于图像之间的光照变化很大,部分遮挡、粗像素损坏以及动态增加的图像,这些巨大的数据对现有的批量图像对齐算法提出了巨大挑战^[2-3]。因此,如何实现低存储且高效率的稳健对齐被认为是处理大量且不断增加的图像量时要解决的关键图像处理问题^[4-5]。

图像对齐问题已被广泛研究^[6-7],相继有众多学者提出了一系列有代表性的方法,如文献[8]通过最小化像素堆叠熵的总和以对齐图像;文献[9]通过稀疏和低秩分解(RASL)为一批线性相关图像实现了鲁棒对齐。在 RASL 中,通过利用对齐图像的低秩特性来建立最佳变换。然而,为了将新到达的图像与先前对齐的图像对齐,RASL 必须调整所有先前的变换以寻求矩阵秩最小化。此外,RASL 将损坏和遮挡建模为稀疏强度误差。然而许多真实世界的损坏图像包含严重的强度失真,这些失真是密集的,难以被 RASL 处理。相比之下,文献[10]将输入图像排列成 3D 张量,并声称可以在梯度和频域中分离出严重的强度失真和部分遮挡,通过同时稀疏频率张量和梯度误差张量来实现最佳的图像对齐张量。但是这种离线对齐方法非常耗费内存和时间,限制了它对齐大量和不断增加的图像的能力。

为了更好地解决动态增加的图像,在线图像对齐已成为一个活跃的研究领域^[11-12]。文献[13]提出了一种在线鲁棒图像对齐(Online Robust Image Alignment, ORIA)方法。文献[14]提出了用于在线图像对齐的 t-GRASTA 算法。文献[15]将几何变换集成到用于图像对齐的在线稳健主成分分析(Robust Principal Component Analysis, RPCA)方法中。以上提出的各种方法都是假设图像之间的大的误差是稀疏的并且相对于强度是可分离的。这可能无法对齐具有严重强度失真的图像。

为了解决上述这些挑战,提出了一种面向图像梯度方向(IGO)的子空间学习的在线图像对齐方法。该方法基于 PCA 的梯度方向,提供了比像素强度更可靠的低维子空间,子空间使在线对齐更加节省内存,因为只需要在整个对齐过程中维护低维子空间。其次,IGO 域中的图像分解和对齐有益于处理光照强度变化巨大或存在遮挡的图像。仿真实验也验证了本文算法的有效性。

1 在线稳健的图像对齐

1.1 IGO 域中的稳健图像对齐

1.1.1 问题描述

本文研究的问题可以表述为:假设已知 n 个先前对齐的灰度图像 $I_1, I_2, \dots, I_n \in \mathbf{R}^{w \times h}$ 的某个主题,其中 w 和 h 是图片的宽度和高度。当有新图像 I 到达时,寻找最佳变换 $\tau: \mathbf{R}^2 \rightarrow \mathbf{R}^2$,用先前对齐的图像来对齐该图像。

传统方法^[13-14]将此任务视为在图像强度域中寻找对齐以使对齐图像可以被分解为稀疏误差之和,以及先前对齐图像的子集的线性组合^[13]或低秩子空间^[14]。这些方法的对齐性能严重依赖于基础图像的质量或它们估计得到的子空间,而且这些方法假设图像之间大的错误(如遮挡和腐蚀)是稀疏的。然而,实际应用中,输入图像的质量被空间变化的强度失真破坏,导致从像素强度估计的子空间被任意偏置,见图 1(a)~图 1(e)。相比之下,来自图像梯度方向(IGO)的 PCA 能够提供比像素强度更可靠的低维子空间。为此,本文不是在强度域中处理图像对齐问题,而是在 IGO 域中寻求图像对齐,使新到达图像的对齐问题可以被分解为稀疏误差和从先前良好对齐图像上学习得到的 IGO-PCA 基的线性组合的总和。因此提出了一种稳健的增量式对齐方法,该方法可以被描述为受约束的 l_1 范数最小化问题:

$$\min_{w, e, \tau} \|e\|_1 \quad \text{s.t. } \text{vec}(\Phi \circ \tau) = U w + e \quad (1)$$

式中: $\Phi \in [0, 2\pi]^{w \times h}$ 为输入图像 I 的 IGO; $I, U \in \mathbf{R}^{d \times k}$ ($d = w \times h$) 为从先前良好对齐的 IGO 中估计得到的低秩正交基; $w \in \mathbf{R}^k$ 为重建权重; $e \in \mathbf{R}^d$ 用来衡量 Φ 和基于子空间 U 重建的梯度方向之间的差异; \circ 表示内积。此外,文中用向量化运算符 $\text{vec}: \mathbf{R}^{w \times h} \rightarrow \mathbf{R}^d$ 将一个矩阵堆叠成一个向量。

为了计算 Φ , 首先用 $G_w = h_x * I$ 和 $G_h = h_y * I$ 来估计图像的梯度,其中 h_x 和 h_y 分别为用于沿着图像水平和垂直方向近似微分算子的滤波器。然后采用式(2)计算梯度方向:

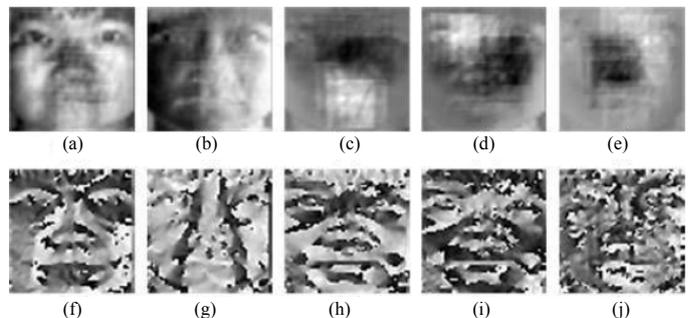


Fig.1 (a)~(e) pixel intensity and (f)~(j) the first five main components of the gradient direction

图 1 (a)~(e)像素强度和(f)~(j)梯度方向的前 5 个主要成分

$$\Phi = \arctan(G_w / G_h) \tag{2}$$

1.1.2 图像对齐：基于 ADMM 的凸优化求解算法

由于变换 τ 的非线性，式(1)中的优化问题是非凸的且难以直接求解。为了解决这一问题，本文通过使用每个 IGO 的局部一阶泰勒将线性化约束近似为 $\Phi o(\tau + \Delta\tau) \approx \Phi o\tau + J\Delta\tau$ ，其中 $\Delta\tau \in \mathbf{R}^p$ 通过参数 p 和 J 来定义，而 $J = \frac{\partial}{\partial \zeta} [\text{vec}(\Phi o \zeta)]|_{\zeta=\tau} \in \mathbf{R}^{d \times p}$ 为 Φ 相对于变换 τ 的雅可比矩阵。因此，式(1)可以松弛为如下的凸优化问题：

$$\min_{w, e, \Delta\tau} \|e\|_1 \text{ s.t. } \text{vec}(\Phi o \tau) + J\Delta\tau = U w + e \tag{3}$$

对于式(3)，本文采用增广拉格朗日乘法^[16](Augmented Lagrangian Multiplier, ALM)进行求解。具体而言，定义了如下的增广拉格朗日函数：

$$L(w, e, \Delta\tau, y, \mu) = \|e\|_1 + y^T f(w, e, \Delta\tau) + \frac{\mu}{2} \|f(w, e, \Delta\tau)\|_2^2 \tag{4}$$

式中： $f(w, e, \Delta\tau) = \text{vec}(\Phi o \tau) + J\Delta\tau - U w - e$ ； $y \in \mathbf{R}^d$ 为拉格朗日乘子； μ 为正超参数。给定当前估计的变换 τ 、雅可比矩阵 J 和子空间 U ，式(4)中的每个子问题可以通过乘子的交替方向法^[9](Alternating Direction Method of Multipliers, ADMM)进行解耦，计算过程如下：

$$\begin{cases} e^{t+1} = S_{\frac{1}{\mu}} \left[\text{vec}(\Phi o \tau) + J\Delta\tau^t - U w^t + \frac{y^t}{\mu^t} \right], & w^{t+1} = U^T \left[\text{vec}(\Phi o \tau) + J\Delta\tau^t - e^{t+1} + \frac{y^t}{\mu^t} \right], \\ \Delta\tau^{t+1} = J^\oplus \left[U w^t + e^{t+1} - \text{vec}(\Phi o \tau) - \frac{y^t}{\mu^t} \right], & y^{t+1} = y^t + \mu^t f(w^{t+1}, e^{t+1}, \Delta\tau^{t+1}), \quad \mu^{t+1} = \rho \mu^t \end{cases} \tag{5}$$

式中： J^\oplus 为 J 的 Moore-Penrose 伪逆； $S_{\frac{1}{\mu}}(x) = \left\{ \left[x - \frac{1}{\mu} \right]_+ - \left[-x - \frac{1}{\mu} \right]_+ \right\}$ 为软阈值算子^[16]，这里的 $[\cdot]_+ = \max(\cdot, 0)$ ； $\rho > 1$ 为惩罚因子，它随着 μ^t 单调递增以加速整个算法的收敛；上标 t 为算法的迭代次数。综上所述，基于 ADMM 的凸优化求解算法如下：

算法 1：针对局部凸问题的 ADMM 求解器

输入：正交基 $U \in \mathbf{R}^{d \times k}$ ；向量化的梯度方向 $x = \text{vec}(\Phi o \tau) \in \mathbf{R}^d$ ；对应的雅可比矩阵 $J \in \mathbf{R}^{d \times p}$ ；惩罚因子 ρ ；公差 ε 和最大迭代次数 $maxIter$

输出：权值向量 $w \in \mathbf{R}^k$ ；稀疏离群值 $e \in \mathbf{R}^d$ ；局部线性化参数 $\Delta\tau \in \mathbf{R}^p$ 和拉格朗日乘子 $y \in \mathbf{R}^d$

1.初始化： $w^0 = 0, \Delta\tau^0 = 0, y = 0, \mu = 1$

2.While $t \leq maxIter$ do

3.更新稀疏离群值 e ： $e^{t+1} = S_{\frac{1}{\mu}} \left(x + J\Delta\tau^t - U w^t + \frac{y^t}{\mu^t} \right)$ ；更新权重向量 w ： $w^{t+1} = U^T \left(x + J\Delta\tau^t - e^{t+1} + \frac{y^t}{\mu^t} \right)$ ；

更新 $\Delta\tau$ ： $\Delta\tau^{t+1} = J^\oplus \left(U w^t + e^{t+1} - x - \frac{y^t}{\mu^t} \right)$ ；更新 y ： $y^{t+1} = y^t + \mu^t f(w^{t+1}, e^{t+1}, \Delta\tau^{t+1})$ ；更新 μ ： $\mu^{t+1} = \rho \mu^t$

If $\|f(w^{t+1}, e^{t+1}, \Delta\tau^{t+1})\|_2 \leq \varepsilon$ then

 算法收敛，退出

End

End

4.返回 $w = w^{t+1}, e = e^{t+1}, \Delta\tau = \Delta\tau^{t+1}$ 和 $y = y^{t+1}$

1.2 在线子空间更新

在描述在线子空间更新策略之前，先简要地说明为什么 U 是对齐的 IGO 低秩部分的主要组成部分。现在假设已知 n 个良好对齐的 IGO 图像及其相应的参数值： $\{w_i, e_i, \Delta\tau_i\}_{i=1}^n$ ，满足式(3)约束条件的最优子空间 U 可以表示为如下的 l_2 范数最小化问题：

$$\min_U \sum_{i=1}^n \|\text{vec}(\Phi_i o \tau_i) + J_i \Delta\tau_i - U w_i - e_i\|_2 \tag{6}$$

设 $R_i = \text{vec}(\Phi_i o \tau_i) + J_i \Delta\tau_i - e_i$ 表示良好对齐的 IGO 低秩部分(此处的 R_i 是 $R_{(i)}$, $i \in [1, n]$ 的简写)。因此，识别最

佳 U 的问题等价于找出 $R \in \mathbf{R}^{d \times n}$ 的主成分, 该问题可以通过 SVD 有效地解决。

一旦 $m(m \geq 1)$ 个新图像与当前基 U 对齐, 就可以得到相应的 $R_{(:,n+j)}, j \in [1, m]$ 。然后通过使用 $R_{(:,n+j)}$ 和一些以前存储的与基相关的变量来逐步更新 U 。目前已经开发出许多算法在新数据到达时有效地更新基^[13-14]。这些算法大多假设在更新特征基时样本均值为零或某一固定值。但是, 在大多数实际应用中, 随着新样本的到来, 样本均值可能会随时间而变化。为解决这个问题, 在进行子空间更新时考虑了新来图像的样本均值, 只要有一个样本到达, 该子空间更新策略就可用。考虑样本均值的变化, 得到以下引理:

引理 1 令 $A = R_{(:,1:n)}, B = R_{(:,n+1:n+m)}$ 是低秩估计数据矩阵, $C = [A, B]$ 是所有估计数据的级联矩阵。 A, B, C 的平均值和散射矩阵分别是 $\bar{R}_A, \bar{R}_B, \bar{R}_C$ 和 S_A, S_B, S_C 。有如下的等式成立:

$$\bar{R}_C = \frac{n}{n+m} \bar{R}_A + \frac{m}{n+m} \bar{R}_B, S_C = S_A + \sum_{i=n+1}^{n+m} (R_i - \bar{R}_C)(R_i - \bar{R}_C)^T + \frac{nm^2}{(n+m)^2} (\bar{R}_A - \bar{R}_B)(\bar{R}_A - \bar{R}_B)^T \quad (7)$$

引理 2 令 $Q = \begin{bmatrix} \Sigma & U^T \hat{B} \\ 0 & \hat{B}^T \hat{B} \end{bmatrix}$, $\tilde{U} \tilde{V}^T$ 表示 Q 的 SVD, 则基矩阵和特征值的更新可用 $U^* = [U \tilde{B}] \tilde{U}$ 和 $\Sigma^* = \tilde{\Sigma}$ 计算得到。

限于文章篇幅, 引理 1 和引理 2 的论证在此略去。综上所述, 本文提出的基于 IGO 的在线图像对齐算法如下:

算法 2: 基于 IGO 的在线图像对齐算法

输入: 初始正交基 $U \in \mathbf{R}^{d \times k}$ 和相应的特征值矩阵 Σ , 新的未对齐图像 I 和相应的初始变换 τ , 差分算子滤波器 h_x, h_y 和最大迭代次数 K

输出: 更新的子空间 U^* 和良好对齐图像的变换 τ^*

1. 计算图像的水平梯度 $G_w = h_x * I$ 和垂直梯度 $G_h = h_y * I$

2. 计算输入图像的梯度方向: $\Phi = \arctan(G_w / G_h)$

3. While 算法还没有收敛 and $iter \leq K$ do

计算 Φ 的雅可比矩阵: $J = \frac{\partial(\Phi \circ \zeta)}{\partial \zeta} \Big|_{\zeta=\tau}$; 更新 $vec(\Phi \circ \tau) = \frac{vec(\Phi \circ \tau)}{\|vec(\Phi \circ \tau)\|_2}$; 利用算法 1 估计: 权重 w , 局

部线性化变换参数 $\Delta \tau$, 稀疏异常值 e 和式(5)中的对偶参数 y ; 更新特征基 U^* , 特征值 Σ^* 和均值 \bar{R}_C ;

更新变换参数: $\tau^* \leftarrow \tau + \Delta \tau$

End

4. 返回 U^*, τ^*

1.3 算法的内存耗费分析

采用一系列 d 像素图像对本文算法和 RASL 算法进行内存耗费分析。当第 N 个待对齐的图像出现时, RASL 算法需要存储所有未对齐图像 D 、已经对齐的图像 $D \circ \tau$ 、低秩成分 A 、稀疏误差 E 和拉格朗日乘子 Y 等信息, 每个都需要大小为 dN 的内存空间。其中在计算 A 时, RASL 方法使用了 k 个奇异值的 SVD, 需要存储 $dk + k^2 + Nk$ 个元素; 对于第 N 个图像的雅可比矩阵 $J_i, \Delta \tau_i$ 和 τ_i , 分别需要存储 dp, p 和 q 个元素。因此, RASL 方法总共需要的内存空间大小为 $(5+p)dN + dk + (k+p+q)N + k^2$ 。

为了公平比较, 假设本文算法在 SVD 过程中使用 k 个基向量。如果每次处理一幅图像, 当第 N 个待对齐的图像出现时, 本文算法需要为 IGO 计算过程存储 (I, G_w, G_h, Φ) 等信息, 其中的每个参数使用了 d 个元素用于图像对齐(见算法 1), 一共存储了 $(e, y, J, \Phi \circ \tau, \tau, \Delta \tau, w, U)$ 等多个参数, 这需要存储 $(3+p+k)d + p + q + k$ 个元素。最后, 对于子空间更新而言, 本文算法需要存储一个额外的参数组 $(\bar{R}_A, \bar{R}_B, \bar{R}_C, \tilde{B}, \hat{B}, Q, U^*, \Sigma^*)$, 这需要存储 $7d + (k+2)^2 + dk + k^2$ 个元素。因此, 本文算法总共需要的内存大小为 $(14+p+2k)d + 2k^2 + 5k + p + q + 4$ 。这表明 RASL 算法所需的内存开销随着 N 的增加而增加, 而本文算法的内存开销是一个常数。对于 100 个未对齐的图像, 假设每副图像的像素为 100×100 , $k=5$ 和仿射变换 $G = Aff(2)$, 当处理到最后一副图像时, 本文算法的内存开销仅为 RASL 算法的 3%。当图像的尺寸较小时, 本文算法的内存耗费相比于 RASL 算法更加节省。

1.4 算法的实现

在算法 1 中, 分别设置 $p=2, \varepsilon=10^{-7}$ 和 $maxIter=100$ 。在算法 2 中, 使用了仿射变换 $G = Aff(2)$ 。为了计算 IGO, 使用了 Sobel 梯度算子。为了获得一个已经训练好的标准正交基 U 作为算法 2 的输入, 首先对一小批图像执行

RASL 算法, 以获得对齐的图像。然后通过 SVD 估算 IGO 域中对齐图像的 PCA, 以得到参数 U 和 Σ 。主成分 k 的数量由 Σ 中的奇异值之和的能量比(在实验中为 95%)自动确定。如果迭代次数达到最大值($k=100$)或者两次连续迭代之间的成本差小于 10^{-7} , 则整个算法终止。在步骤 3 中, 当输入 IGO 与当前基良好对齐时, 更新基。即对于特定阈值 $\delta=1$, 本文算法具有小的重建误差 $\|e\|_2 \leq \delta$ 。

2 仿真实验

为了验证本文方法的有效性和稳健性, 将其与目前 3 种最先进的图像对齐算法进行性能比较: SIFT^[8], RASL^[9]和 t-GRASTA^[14]。

2.1 图像对齐

首先演示了本文算法用于递增地对齐视频序列 Gore 的效用, 其包含由面部检测器获得的 140 帧 Al Gore 的面部图像。图 2 给出了本文算法在 Gore 数据集上的 20 个均匀采样帧的对齐结果。其中, 第 1 行是来自 140 帧 Gore 的 20 个均匀采样帧; 第 2 行: 本文方法对应的对齐帧。可以看到, 本文方法可以在顺序图像上产生非常稳定的对齐。



Fig.2 Alignment results of video sequences in Gore
图 2 Gore 中视频序列的对齐结果

测试本文算法在更具挑战性和无约束的图像数据集(LFW)^[18]上的对齐结果。对于每个受试者, 将原始未对齐图像的鼻尖、左眼和右眼注释为地标。图 3 给出了不同算法的对齐结果: 图 3(a)表示不同受试者的平均面部, 即原始图像; 图 3(b)为本文算法的对齐结果; 图 3(c)为 SIFT 算法的对齐结果; 图 3(d)为 RASL 算法的对齐结果; 图 3(e)为 t-GRASTA 算法的对齐结果。可以看到, 采用本文算法对齐后的平均面部比对齐前的平均面部明显更锐利。此外, 本文方法比 t-GRASTA 和 SIFT 有更清晰的对齐性能, 特别是在眼睛和嘴巴区域(见图 3(c)和图 3(e)中方框区域)。



Fig.3 Alignment results of different algorithms on LFW
图 3 不同算法在 LFW 上的对齐结果

这些结果表明, 从本文方法中嵌入的图像梯度方向和基更新策略的子空间学习有助于图像对齐的改进。同时, 本文算法具有与 RASL 算法几乎相同的对齐性能, 但是计算成本要远远低于 RASL 算法。在具有 Intel Xeon E5-1620 3.70 GHz CPU 和 16.0 GB RAM 以及 Matlab 实现的工作站上, 本文算法平均花费 0.7 s 来对齐新到达的图像, 而 RASL 算法平均需要 673.6 s(逐步对齐每个图像的所有图像主题, 图像逐个输入 RASL)或 19.2 s(对齐单张图片)。

2.2 遮挡和光照变化

为了验证本文算法的稳健性, 在具有遮挡和光照变化的 Dummy 数据集^[9]上进行实验。图 4 给出了不同算法的对齐结果: 图 4(a)为原始未对齐图像; 图 4(b)为本文算法的对齐结果; 图 4(c)为 SIFT 算法的对齐结果; 图 4(d)

为 RASL 算法的对齐结果；图 4(e)为 t-GRASTA 算法的对齐结果。本文算法与 RASL 算法一起可以成功对齐遮挡图像，而 t-GRASTA 算法或 SIFT 算法无法提供稳健的对齐。

进一步在 LFW 数据集的图像上添加人工阴影，并在这些图像上测试本文算法。所有添加的阴影都是随机生成的，具有各种形状和强度。图 5 显示了特定主题 (Gloria Macapagal Arroyo) 的一些对齐结果：图 5(a)为原始未对齐图像，用红色框标记的图像被人工遮挡阴影；图 5(b)为本文算法的对齐结果；图 5(c)为 SIFT 算法的对齐结果；图 5(d)为 RASL 算法的对齐结果；图 5(e)为 t-GRASTA 算法的对齐结果。显然，本文算法实现了整体最佳对齐，特别是对于那些带阴影的图像，而 SIFT, RASL 和 t-GRASTA 都不能很好地处理带阴影的图像。本文方法比文献[14,18]中的算法更实用。值得注意的是，图 5(a)中的最后 1 个输入图像在脸上包含自然阴影，所有其他算法都不能很好地对齐它，而本文算法可以很好地将它与其他图像对齐。



Fig.4 Alignment results of virtual faces
图 4 虚拟面部的对齐结果

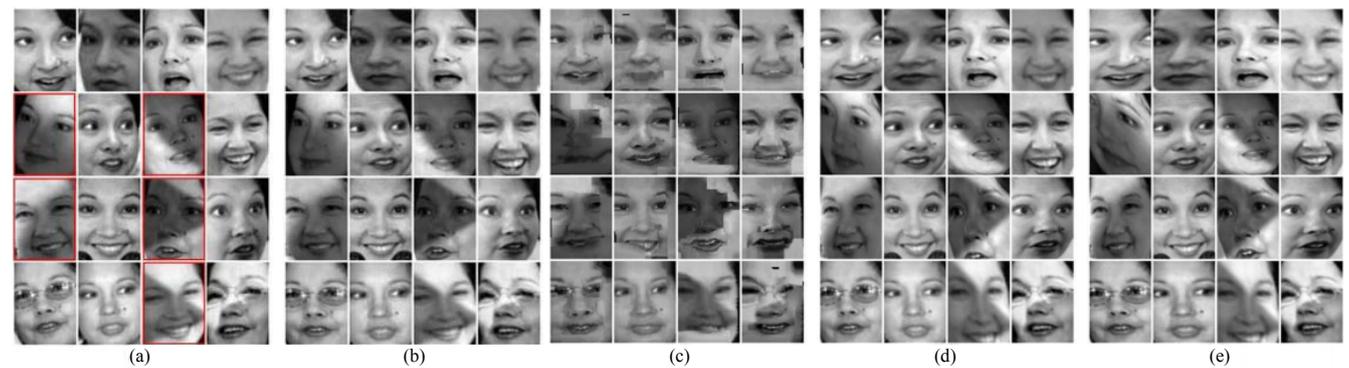


Fig.5 Result of topic-specific comparisons from LFW datasets
图 5 来自 LFW 数据集的特定主题的比对结果

3 结论

由于现实环境中的图像是动态增加的并且图像之间存在很大的强度变化(如光照变化、部分遮挡和损坏等)，因此，图像对齐是一个巨大的难题。为了解决这个难题，本文通过图像梯度方向的子空间学习提出了一种在线图像对齐方法。通过图像对齐和工件检测等实验验证了所提方法对广泛挑战数据集的有效性。实验结果表明，所提算法比现有的方法能够更加稳健可靠地实现图像对齐。下一步工作中，将针对复杂背景下图像边缘检测中存在抗噪性能不强、边缘不连续等问题，采用人工智能中的深度学习理论来研究一种多卷积网络的图像边缘检测算法，以进一步提高检测的质量。

参考文献：

- [1] LIAO D, QIAN Y, ZHOU J, et al. A manifold alignment approach for hyperspectral image visualization with natural color[J]. IEEE Transactions on Geoscience & Remote Sensing, 2016, 54(6):3151–3162.
- [2] LIU L, YU M, SHAO L. Multiview alignment Hashing for efficient image search[J]. IEEE Transactions on Image Processing, 2015, 24(3):956–966.
- [3] ASTHANA A, ZAFEIRIOU S, TZIMIROPOULOS G, et al. From pixels to response maps: discriminative image filtering for face alignment in the wild[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(6):1312–1320.
- [4] 刘金华, 韦家军, 孙梧雨, 等. 基于 SoPC 的视频图像快速去雾[J]. 太赫兹科学与电子信息学报, 2019, 17(2):309–314. (LIU Jinhua, WEI Jiajun, SUN Wuyu, et al. Fast dehazing for video image based on SoPC[J]. Journal of Terahertz Science and Electronic Information Technology, 2019, 17(2):309–314.)

(下转第 895 页)