

一种基于低秩恢复稀疏表示分类器的人脸识别方法

杜海顺 张旭东 侯彦东 金 勇

(河南大学图像处理与模式识别研究所 开封 475004)

摘 要 针对基于稀疏表示分类器(Sparse Representation-based Classification, SRC)的人脸识别方法用单位阵作误差字典不能很好地描述人脸图像噪声和误差以及由于训练样本不足可能造成字典不完备的问题,提出一种基于低秩恢复稀疏表示分类器(Low Rank Recovery Sparse Representation-based Classification, LRR_SRC)的人脸识别方法。该方法首先采用低秩矩阵恢复(LRR)算法将训练样本矩阵分解为一个低秩逼近矩阵和一个稀疏误差矩阵。然后,由低秩逼近矩阵和误差矩阵组成字典。在此基础上,得到测试样本在该字典下的稀疏表示。更进一步,基于测试样本的稀疏表示系数和字典,对测试样本进行类关联重构,并计算其类关联重构误差。最后,基于类关联重构误差,完成测试样本的分类识别。在YaleB和CMU PIE人脸数据库上的实验结果表明,提出的基于LRR_SRC的人脸识别方法具有较高的识别率。

关键词 低秩矩阵恢复,稀疏表示,误差字典,人脸识别

中图法分类号 TP391.4 **文献标识码** A

Face Recognition Method Based on Low-rank Recovery Sparse Representation Classifier

DU Hai-shun ZHANG Xu-dong HOU Yan-dong JIN Yong

(Institute of Image Processing and Pattern Recognition, Henan University, Kaifeng 475004, China)

Abstract A face recognition method based on low-rank recovery sparse representation classifier (LRR_SRC) was proposed to overcome the disadvantages of the face recognition of sparse representation-based classification (SRC), including the poor performance of the unit matrix as the error dictionary in the progress of describing the noise and error of the face images, and the dictionary incompleteness caused by the insufficiency of the training samples. Firstly, in this method, training samples are decomposed into a low rank approximation matrix and a sparse error matrix using low-rank recovery (LRR) algorithm. And then, the low-rank approximation matrix and the error matrix compose a dictionary. On the basis of this, the sparse representation of the given test sample can be obtained under this dictionary. Further, using the sparse coefficients associated with the special class, LRR_SRC can approximate the given test sample and calculate the reconstruction error between the given test sample with its approximation associated with the special class. Based on the reconstruction error associated with special class, the given test sample can be classified accurately. Experimental results on face database of YaleB and CMU PIE show that face recognition method proposed in this paper has a higher recognition rate.

Keywords Low rank matrix recovery, Sparse representation, Error dictionary, Face recognition

1 引言

随着压缩感知理论和 l_1 范数最优化技术的发展,近年来稀疏表示受到了国内外众多学者的关注。在稀疏表示下,一个信号可以表示为给定字典原子的最稀疏线性组合。研究表明,稀疏表示模型与人类视觉系统的原理非常类似^[1]。因此,近年来稀疏表示被广泛应用于图像去噪^[2]、图像恢复^[3,4]、图像理解^[5]等计算机视觉领域。2009年,John Wright等人将稀疏表示推广应用到人脸识别领域,提出了基于稀疏表示分类器(SRC)的人脸识别方法^[6,7]。该方法在人脸图像受噪声污染或有其它误差干扰情况下,取得了较好的识别效果。然

而, SRC算法仍存在如下不足:(1) SRC虽然通过用单位阵作误差字典,较好地解决了图像受噪声污染或有其它误差干扰情况下的人脸识别问题,但是采用与数据同维的单位阵作误差字典使后续的稀疏分解运算计算量过高,且单位阵对噪声和误差描述不太直观;(2) 由于 SRC算法直接用训练样本构成字典,因此在样本不足的情况下,字典可能是不完备的,从而不能满足图像稀疏表示的需要,最终导致基于 SRC的人脸识别方法识别率较低。

为解决 SRC的不足,2012年Deng等人提出了扩展 SRC(ESRC)方法^[8],该方法在采用训练样本作基本字典的同时,用训练样本减去其对应的类均值作误差字典,得到了人脸图

到稿日期:2013-05-14 返修日期:2013-08-12 本文受国家自然科学基金(U1204611),河南省科技厅基础与前沿技术研究计划项目(132300410474),河南省教育厅科学技术重点研究项目(12A520008)资助。

杜海顺(1977—),男,博士,副教授,硕士生导师,主要研究方向为图像处理、模式识别、数据融合等, E-mail: jddhs@henu.edu.cn; 张旭东(1985—),男,硕士生,主要研究方向为图像处理、模式识别。

像较好的稀疏表示,提高了基于稀疏表示分类器人脸识别方法的识别性能。另外,由于引入了误差字典,ESRC也在一定程度上解决了由于样本不足造成的字典不完备问题。然而,ESRC采用训练样本减去其对应的类均值作误差字典,并不能很好地描述人脸图像噪声和误差。近年来,E. Candes等人提出了一种矩阵低秩恢复算法(Low Rank Matrix Recovery, LRR)^[9,10],其能够将训练样本矩阵分解为一个低秩逼近矩阵和一个稀疏误差矩阵。本文研究发现,LRR分解得到的低秩逼近矩阵和误差矩阵可以分别很好地描述同类人脸样本图像的共同特征、噪声以及误差。基于此,本文提出一种基于低秩恢复稀疏表示分类器(LRR_SRC)的人脸识别方法。具体地,LRR_SRC首先采用矩阵低秩恢复算法将训练样本矩阵分解为一个低秩逼近矩阵和一个稀疏误差矩阵。然后,由低秩逼近矩阵和误差矩阵组成字典。在此基础上,得到测试样本在该字典下的稀疏表示。更进一步,基于测试样本的稀疏表示系数和字典,对测试样本进行类关联重构,并计算其类关联重构误差。最后,基于类关联重构误差,完成测试样本的分类别。

2 SRC 和 ESRC 概述

2.1 SRC

假设有 k 类训练样本,矩阵 $D_i = [d_{i1}, d_{i2}, \dots, d_{in_i}] \in \mathbb{R}^{d \times n_i}$ 为第 i 类训练样本构成的矩阵,其中, n_i 为第 i 类训练样本的个数。则矩阵 $D = [D_1, D_2, \dots, D_k] \in \mathbb{R}^{d \times n}$ 为训练样本集,其中, n 为训练样本的总数, $n = \sum_i n_i$ 。把矩阵 D 当成一个字典,则给定的测试样本 y 可由字典 D 表示,即 $y = Dx$ 。SRC认为,测试样本 y 可由与它同类的训练样本充分表示。因此,在训练样本集 D 中的样本个数足够多的情况下, y 在 D 下的表示显然是稀疏的。同时 SRC 指出, y 的稀疏表示系数向量 x 越稀疏,越有利于该测试样本的分类。

SRC 通过求解如下 l_1 范数最优化问题,得到 $y = Dx$ 的最稀疏解:

$$\hat{x}_1 = \arg \min \|x\|_1 \quad \text{s. t.} \quad \|y - Dx\|_2 \leq \epsilon \quad (1)$$

迄今为止,国内外学者针对求解 l_1 范数最优化问题提出了很多有效的算法,其中最常用的有 GPSR^[11]、Homotopy^[12]、FIST^[13]、和 l_1 -ls^[14] 等。

在得到稀疏系数向量 \hat{x}_1 的基础上,令 $\delta_i(\hat{x}_1)$ 为与 \hat{x}_1 同维,且仅保留 \hat{x}_1 中与第 i 类对应的非零元素而其它元素为零的向量。采用 $\delta_i(\hat{x}_1)$,可以得到与第 i 类关联的重构测试样本: $y_i = D\delta_i(\hat{x}_1)$ 。更进一步,可得到 y 与 y_i 的类关联重构误差:

$$r_i(y) = \|y - D\delta_i(\hat{x}_1)\|_2, i=1, 2, \dots, k \quad (2)$$

基于重构误差, SRC 给出分类规则如下:

$$\text{label}(y) = \arg \min_i r_i(y) \quad (3)$$

式中, $\text{label}(y)$ 表示测试样本 y 的类别标签。

在实际应用中,人脸图像一般会受噪声污染,同时可能有光照、局部遮挡等其它误差。为此, SRC 引入单位阵 $I \in \mathbb{R}^{d \times d}$ 作误差字典来描述人脸图像噪声和误差。也就是说,对于给定测试样本 y ,可由字典 $[D, I] \in \mathbb{R}^{d \times (n+d)}$ 稀疏表示,即问题(1)可以转化为:

$$\begin{bmatrix} \hat{x}_1 \\ \hat{\beta}_1 \end{bmatrix} = \arg \min \left\| \begin{bmatrix} x \\ \beta \end{bmatrix} \right\|_1 \quad \text{s. t.} \quad \left\| [D, I] \begin{bmatrix} x \\ \beta \end{bmatrix} - y \right\|_2 \leq \epsilon \quad (4)$$

相似地,通过求解 l_1 范数最优化问题(3)得到 \hat{x}_1 和 $\hat{\beta}_1$ 后,采用式(5)得到测试样本与第 i 类关联重构测试样本的类关联重构误差:

$$r_i(y) = \|y - D\delta_i(\hat{x}_1) - \hat{\beta}_1\|_2, i=1, 2, \dots, k \quad (5)$$

基于 $r_i(y)$,采用式(2)的分类规则,可以完成测试样本 y 的分类。

2.2 ESRC

SRC 虽然通过用单位阵作误差字典,较好地解决了图像受噪声污染或局部有一定程度遮挡误差情况下的人脸识别问题,但是采用与数据同维的单位阵作误差字典使后续的稀疏分解运算计算量过高,且单位阵对噪声和误差描述不太直观。为解决这一问题, Deng 等提出扩展 SRC(ESRC)算法,采用 $D_i = [D_i - m_i e_1, D_i - m_i e_2, \dots, D_i - m_i e_k] \in \mathbb{R}^{d \times n}$ 描述人脸图像噪声和误差。其中, D_i 为第 i 类训练样本构成的矩阵; m_i 为第 i 类训练样本的均值; e_i 为 $[1, \dots, 1] \in \mathbb{R}^{1 \times n_i}$ 。由此,对于给定测试样本 y ,可由字典 $[D, D_i] \in \mathbb{R}^{d \times 2n}$ 稀疏表示。求解如下目标函数:

$$\begin{bmatrix} \hat{x}_1 \\ \hat{\beta}_1 \end{bmatrix} = \arg \min \left\| \begin{bmatrix} x \\ \beta \end{bmatrix} \right\|_1 \quad (6)$$

$$\text{s. t.} \quad \left\| [D, D_i] \begin{bmatrix} x \\ \beta \end{bmatrix} - y \right\|_2 \leq \epsilon$$

可得 \hat{x}_1 和 $\hat{\beta}_1$ 。更进一步, ESRC 采用式(7)得到测试样本与第 i 类关联重构测试样本的类关联重构误差:

$$r_i(y) = \|y - D\delta_i(\hat{x}_1) - D_i \hat{\beta}_1\|_2, i=1, 2, \dots, k \quad (7)$$

基于 $r_i(y)$, ESRC 同样采用式(3)的分类规则完成测试样本 y 的分类。

3 LRR_SRC

虽然 ESRC 采用训练样本减去其对应的类均值作误差字典比单位阵 I 对噪声和误差描述更加直观,但本文研究发现, LRR 算法分解得到的稀疏误差矩阵 E 可以更好地描述人脸图像的噪声,并且其低秩逼近矩阵 A 也能够很好地描述同类样本图像的共同特征。LRR 算法能将一个受噪声污染和误差干扰的训练样本矩阵 D 分解为一个低秩逼近矩阵 A 和一个误差矩阵 E ,且 $D = A + E$ 。具体算法如算法 1 所示^[15]。

算法 1 LRR 算法

1. 输入:数据矩阵 D 、参数 $\lambda > 0$
 2. $Y_0 = D / \max(\|D\|_2, \lambda^{-1} \|D\|_\infty)$; $\mu_0 > 0$; $\rho > 1$; $k = 0$ 。
重复
 3. $(U, S, V) = \text{svd}(D - E_k + \mu_k^{-1} Y_k)$;
 4. $A_{k+1} = US_{\mu_k}^{-1} [S] V^T$;
 5. $E_{k+1} = S_{\mu_k}^{-1} [D - A_{k+1} + \mu_k^{-1} Y_k]$;
 6. $Y_{k+1} = Y_k + \mu_k (D - A_{k+1} - E_{k+1})$;
 $\mu_{k+1} = \rho \mu_k$;
 7. $k \leftarrow k + 1$;
- 直到收敛
8. 输出:低秩逼近矩阵 A 、稀疏误差矩阵 E

算法1中步骤3和步骤4中用到的 $S_\epsilon[X]$ 为矩阵软阈值操作^[9],即:

$$S_\epsilon[X] = \begin{cases} X_{ij} - \epsilon, & \text{if } X_{ij} > \epsilon \\ X_{ij} + \epsilon, & \text{if } X_{ij} < -\epsilon \\ 0, & \text{otherwise} \end{cases} \quad (8)$$

其中, $\epsilon > 0$ 。

为了形象地说明 LRR 分解得到的稀疏误差矩阵 E 比 ESRC 算法中 D_i 能更好地描述人脸图像噪声和遮挡误差,本文以 CMU PIE 数据库^[17]部分人脸图像为例对它们进行了充分比较。

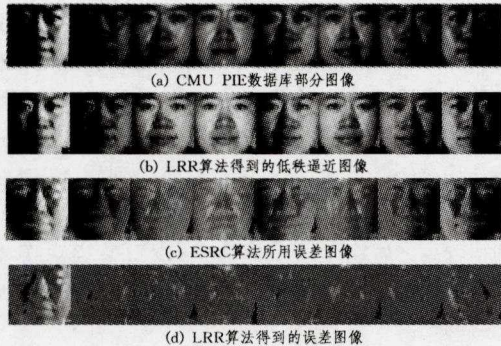


图1 人脸图像误差描述对比图

由图1可以看出,LRR分解得到的误差矩阵 E 能够很好地描述人脸图像误差。基于此,本文提出一种基于低秩恢复稀疏表示分类器(LRR_SRC)的人脸识别方法。假设 $D = [D_1, D_2, \dots, D_k] \in \mathbb{R}^{d \times n}$ 为训练样本集,其中 $D_i = [d_{i1}, d_{i2}, \dots, d_{in_i}] \in \mathbb{R}^{d \times n_i}$ 为第 i 类训练样本构成的矩阵, d_{ij} 表示第 i 类第 j 个训练样本。LRR_SRC 采用算法1求解如下最优化问题得到 D_i 的低秩逼近矩阵 A_i 和误差矩阵 E_i :

$$\min_{A_i, E_i} \|A_i\|_* + \lambda \|E_i\|_1 \quad (9)$$

$$\text{s. t. } D_i = A_i + E_i, i=1, 2, \dots, k$$

由此,得到训练样本集 D 的低秩逼近矩阵 $A = [A_1, A_2, \dots, A_k] \in \mathbb{R}^{d \times n}$ 和误差矩阵 $E = [E_1, E_2, \dots, E_k] \in \mathbb{R}^{d \times n}$ 。

本文采用矩阵 A 和 E 组成字典 $[A, E] \in \mathbb{R}^{d \times 2n}$, 则给定测试样本 y 可由字典 $[A, E]$ 稀疏表示。求解如下范数最优化问题,可得到 $y = [A, E][x, \beta]^T$ 的解:

$$\begin{bmatrix} \hat{x}_1 \\ \hat{\beta}_1 \end{bmatrix} = \arg \min \left\| \begin{bmatrix} x \\ \beta \end{bmatrix} \right\|_1 \quad (10)$$

$$\text{s. t. } \left\| [A, E] \begin{bmatrix} x \\ \beta \end{bmatrix} - y \right\|_2 \leq \epsilon$$

在得到 \hat{x}_1 和 $\hat{\beta}_1$ 后,本文采用与 SRC 相同的方式定义 $\hat{\delta}_i(x_1)$ 。并基于此,可以得到与第 i 类关联的重构测试样本: $\hat{y}_i = A\hat{\delta}_i(x_1) + E\hat{\beta}_1$ 。更进一步,采用下式可得到 y 与 \hat{y}_i 的类关联重构误差:

$$r_i(y) = \|y - A\hat{\delta}_i(x_1) - E\hat{\beta}_1\|_2, i=1, 2, \dots, k \quad (11)$$

同样,基于类关联重构误差 $r_i(y)$, LRR_SRC 给 ESRC 同样采用式(3)的分类规则完成测试样本 y 的分类。

LRR_SRC 具体算法步骤如算法2所示。

算法2 LRR_SRC 算法

1. 输入:训练样本集矩阵 $D = [D_1, D_2, \dots, D_k] \in \mathbb{R}^{d \times n}$, 测试样本 y , 参数 $\lambda > 0, \epsilon > 0$

2. 把矩阵 D 分解成一个低秩逼近矩阵 A 和一个误差矩阵 E :

$$\text{for } i=1:k \text{ do } \min_{A_i, E_i} \|A_i\|_* + \lambda \|E_i\|_1 \quad \text{s. t. } D_i = A_i + E_i$$

end for

3. 将 A 和 E 的每列采用随机脸法^[7]降维,并进行 l_2 范数归一化
4. 求解 l_1 最优化问题:

$$\begin{bmatrix} \hat{x}_1 \\ \hat{\beta}_1 \end{bmatrix} = \arg \min \left\| \begin{bmatrix} x \\ \beta \end{bmatrix} \right\|_1 \quad \text{s. t. } \left\| [A, E] \begin{bmatrix} x \\ \beta \end{bmatrix} - y \right\|_2 \leq \epsilon$$

5. 计算类关联重构误差:

$$r_i(y) = \|y - A\hat{\delta}_i(x_1) - E\hat{\beta}_1\|_2, i=1, 2, \dots, k$$

6. 输出:测试样本 y 的类别标签

$$\text{label}(y) = \arg \min_i r_i(y)$$

4 实验

为了评估 LRR_SRC 的性能,本文在 YaleB 和 PIE 两个数据库上,分别采用 SRC、ESRC 和 LRR_SRC 进行人脸识别实验。实验时,本文采用随机脸法^[7]将训练样本特征维数降到 50、75、100、125、200、300、500。另外需要说明的是,本文实验中 3 种方法都采用 l_1 方法^[14]求解 l_1 范数最优化问题。

4.1 YaleB 数据库

YaleB 数据库^[16]包含 38 个人共 2414 张人脸图像。每张图像为 256 个灰度级,分辨率为 243×320 。该数据库中的人脸图像光照、表情以及拍摄角度都有较大程度的变化。本文对 YaleB 数据库中的每张图像都以眼睛为中心进行了剪切和对齐处理,并将其大小缩放为 32×32 像素。YaleB 数据库中的部分人脸图像如图 2(a)所示。





图2 人脸数据库部分图像



分别为每人(a)前8张、(b)前16张、(c)前半图像构成训练样本集时,3种方法的识别率比较曲线

图3 YaleB 数据库上 LRR_SRC、SRC、ESRC 人脸识别率比较曲线

在 YaleB 数据库上,本文分别从每个人的所有图像中选择前 8 张、前 16 张和前半图像构成训练样本集,其余的图像作为测试样本集进行人脸识别实验。图 3 给出了 YaleB 数据库上,LRR_SRC 与 SRC、ESRC 随特征维数变化的识别率曲线的比较。表 1 给出了 YaleB 数据库上,LRR_SRC 与 SRC、ESRC 最高识别率及相应特征维数的比较。由图 3 和

表 1 可以看出,当训练样本为每人 8 张图像时,LRR_SRC 的识别率远高于 SRC 和 ESRC,当训练样本数为每人 16 张和一半图像时,LRR_SRC 的识别率也优于 SRC 和 ESRC。

表 1 YaleB 数据库上 LRR_SRC、SRC、ESRC 最高人脸识别率(%)比较

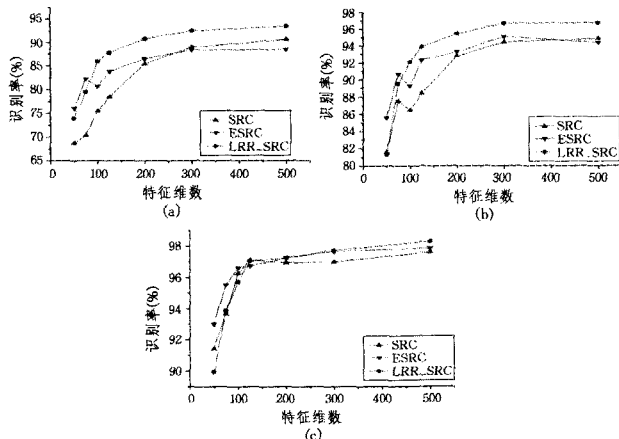
算法	前 8 个	前 16 个	前一半
SRC	47.35(300)	59.41(500)	65.98(500)
ESRC	43.89(300)	56.42(500)	59.00(500)
LRR_SRC	62.23(500)	62.68(500)	71.20(500)

注:括号中的数字代表该识别率所对应的特征维数

4.2 CMU PIE 数据库

CMU PIE 数据库^[17]共有 68 个人 41368 张图像,其中每个人的图像有 13 种姿态条件、43 种光照条件和 4 种表情。本文选择姿态 C27 子集作为实验数据库。CMP PIE C27 子集中共有 68 人的 3329 张图像,每人大约 49 张图像。对 CMP PIE C27 子集中的图像,本文以眼睛为中心进行了剪切和对齐处理,其大小缩放为 64×64 像素。CMU PIE C27 数据库子集中的部分人脸图像如图 2(b)所示。

在 CMU PIE C27 子集上,本文分别从每个人所有图像中选择前 10 张、前 12 张和前半图像构成训练样本集,其余图像构成测试样本集进行人脸识别实验。图 4 给出了 CMU PIE C27 子集上,LRR_SRC 与 SRC、ESRC 随特征维数变化的识别率曲线比较。表 2 给出了 CMU PIE C27 子集上,LRR_SRC 与 SRC、ESRC 最高识别率及相应特征维数的比较。由图 4 和表 2 可以看出,在 CMU PIE C27 子集上,当训练样本数为每人 10 和 12 张图像时,LRR_SRC 的识别率优于 SRC 和 ESRC;当训练样本数为每人一半图像时,LRR_SRC 的识别率略高于 SRC 和 ESRC。



分别为每人 (a) 前 10 张、(b) 前 12 张、(c) 前半图像构成训练样本集时,3 种方法的识别率比较曲线

图 4 CMU PIE C27 子集上 LRR_SRC、SRC、ESRC 人脸识别率比较曲线

表 2 CMU PIE C27 子集上 LRR_SRC、SRC、ESRC 最高人脸识别率(%)比较

算法	前 10 个数据	前 12 个数据	前一半数据
SRC	90.56(500)	94.87(500)	97.61(500)
ESRC	88.45(500)	95.11(300)	97.85(500)
LRR_SRC	93.47(500)	96.75(500)	98.28(500)

注:括号中的数字代表该识别率所对应的特征维数

由 YaleB 和 CMU PIE 人脸数据库上的实验结果可以看出,当训练样本数相同时,在大多数训练样本特征维数下,基于 LRR_SRC 的人脸识别方法识别率都高于基于 SRC 和 ES-

RC 的人脸识别方法。这是可以理解的,由前面分析可知,LRR 分解得到的低秩逼近矩阵和稀疏误差矩阵可以分别很好地描述同类人脸样本图像的共同特征、噪声以及误差。因此,采用 LRR 分解得到的低秩逼近矩阵和稀疏误差矩阵组成字典,能够更好地对测试样本图像进行稀疏表示,从而使得基于 LRR_SRC 的人脸识别方法具有较高的识别率。另外,还可以由实验结果看出,训练样本数越少,LRR_SRC 人脸识别方法的优越性越明显。这说明 LRR_SRC 方法在一定程度上解决了由于训练样本不足造成的字典不完备问题。

结束语 本文研究发现,LRR 分解得到的低秩逼近矩阵和稀疏误差矩阵可以分别很好地描述同类训练样本图像的共同特征、噪声以及误差。基于此,本文提出一种基于低秩恢复稀疏表示分类器(LRR_SRC)的人脸识别方法。与 SRC、ESRC 不同,由于 LRR_SRC 采用 LRR 分解得到的低秩逼近矩阵和稀疏误差矩阵组成字典,因此能够得到测试样本图像更加有效的稀疏表示,最终使得基于 LRR_SRC 的人脸识别方法识别率较高。另外,由于在字典中引入了误差矩阵,也使得 LRR_SRC 在一定程度上解决了由于训练样本不足造成的字典不完备问题。

参考文献

- [1] Vinje W E, Gallant J L. Sparse coding and decorrelation in primary visual cortex during natural vision [J]. *Science*, 2000, 287 (5456): 1273-1276
- [2] Elad M, Aharon M. Image denoising via sparse and redundant representations over learned dictionaries [J]. *IEEE Trans. Image Processing*, 2006, 15(12): 336-3745
- [3] Mairal J, Elad M, Sapiro G. Sparse representation for color image restoration [J]. *IEEE Trans. Image Processing*, 2008, 17(1): 53-69
- [4] Mairal J, Bach F, Ponce J, et al. Nonlocal sparse models for image restoration [C]//*Proc. ICCV. 2009*: 2272-2279
- [5] Wang C, Yan S, Zhang L, et al. Multi-Label Sparse coding for automatic image annotation [C]//*Proc. IEEE Conf. CVPR. 2009*: 1643-1650
- [6] Wright J, Ma Y, Mairal J, et al. Sparse Representation for Computer Vision and Pattern Recognition [J]. *Proc. IEEE*, 2010, 98 (6): 1031-1044
- [7] Wright J, Yang A Y, Ganesh A, et al. Robust Face Recognition via Sparse Representation [J]. *IEEE Trans. Pattern Anal. Mach. Intel.*, 2009, 31(2): 210-227
- [8] Deng W H, Hu J, Guo J. Extended SRC: Undersampled Face Recognition via Intra-Class Variant Dictionary [J]. *IEEE Trans. Pattern Anal. Mach. Intel.*, 2012, 34(9): 1864-1870
- [9] Cai J, Candes E, Shen Z. A singular value thresholding algorithm for matrix completion [J]. *SIAM Journal of Optimization*, 2010, 20(4): 1956-1982
- [10] Candes E, Li X D, Ma Y, et al. Robust principal component analysis? [J]. *Journal of the ACM*, 2011, 58(3)
- [11] Figueiredo M, Nowak R, Wright S. Gradient projection for sparse reconstruction: Application to compressed sensing and other inverse problems [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2007, 1(4): 586-597

[12] Malioutov D, Cetin M, Willsky A. Homotopy continuation for sparse signal representation[C]//Proc. ICASSP. 2005

[13] Beck A, Teboulle M. A fast iterative shrinkage-thresholding algorithm for linear in-verse problems[J]. SIAM Journal on Imaging Sciences, 2009(2): 183-202

[14] Kim S-J, Koh K, Lustig M, et al. A method for large-scale l1-regularized least squares [J]. IEEE Journal on Selected Topics in Signal Processing, 2007, 1(4): 606-617

[15] Lin Z, Chen M, Wu L, et al. The augmented Lagrange multiplier

method for exact recovery of corrupted low-rank matrices [R]. UIUC Tech. Rep. UILU-ENG-09-2215. 2009

[16] Georghiadis A S, Belhumeur P N, Kriegman D J, et al. From few to many: illumination cone models for face recognition under variable lighting and pose [J]. IEEE Trans. Pattern Anal. Mach. Intelligence, 2001, 23(6): 643-660

[17] Sim T, Baker S, Bsat M. The CMU pose, illumination, and expression database [J]. IEEE Trans. Pattern Anal. Mach. Intell. , 2003, 25(12): 1615-1618

(上接第 308 页)

如图 3 所示,由于基于 CPDA 的角点检测算法采取点到弦的距离累积来代替曲率的计算,而点到弦的计算完全是基于欧氏距离的,并不涉及到一阶二阶求导,并且也不需要图像进行较大尺度的平滑,因此它们的角点重复率和角点定位误差均优于基于 CSS 的角点检测算法。而 FCPDA 算法首先在“单尺度”下获取角点候选集合,从而能提高角点的定位精度,并且邻近角点也能被很好地区分,所以角点定位误差低于 CPDA、FAST-CPDA,并且保持了原有算法的高角点重复率。




图 3 各种算法的比较结果

表 1 所列为各种角点检测算法所需的平均时间,统一采用 Windows XP 系统,处理器为 Intel(R) Core(TM) i5, 3.10 GHz,可用内存为 3.24GB。从表中可以看出,所提算法的计算时间相对于原 CPDA 算法有很大的提高,虽然比 FAST-CPDA 算法的运量时间长了一点,但 FCPDA 算法解决了 CPDA 算法存在的前 3 个问题。

表 1 算法运行时间

检测器	运行时间
CSS	0.0079s
MSCP	0.0060s
ACSS	0.0085s
CPDA	0.0128s
FAST_CPDA	0.0047s
FCPDA	0.0056s

结束语 为了在保持算法准确性的前提下解决基于点到弦距离累加的角点检测算法时间复杂度较大的问题,所提算法首先在“单尺度”下对图像进行了候选角点的预检测,使得候选角点的数量大大减少,并保留了邻近角点。然后结合了“多尺度”下真实角点和伪角点能被更好地区分的特性以及构造曲线自适应阈值、角点局部自适应阈值,实现了角点准确的提取。接着通过将 4 种基于 CPDA 的算法进行比较,验证了所提算法能有效地对图像进行邻近角点和钝形角点的提取,并且有效地去除圆形角点。最后通过与经典算法进行实验对比来验证了所提算法在保持高鲁棒性的同时降低了算法的时

间复杂度。

参考文献

[1] 仇国庆,冯汉青,蒋天跃,等.一种改进的 Harris 角点图像拼接算法[J]. 计算机科学,2012,39(11):264-266

[2] Rosten E, Porter R, Drummond T. Faster and better: A machine learning approach to corner detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(1): 105-119

[3] 梁艳菊,李庆,陈大鹏,等.一种快速鲁棒的 LOG-FAST 角点算法[J]. 计算机科学,2012,39(6):251-254

[4] 张小洪,杨丹.使用梯度相关矩阵行列式的角点检测算法[J]. 中国图象图形学报,2009,14(8):1601-1608

[5] Mokhtarian F, Suomela R. Robust image corner detection through curvature scale space [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(12): 1376-1381

[6] He X C, Yung N H C. Corner detector based on global and local curvature properties [J]. Optical Engineering, 2008, 47(5): 057008-1-12

[7] Zhang X H, Lei M, Yang D, et al. Multi-scale curvature product for robust image corner detection in curvature scale space [J]. Pattern Recognition Letters, 2007, 28(1): 545-554

[8] Sarfraz M, Masood A, Asim M R. A new approach to corner detection [J]. Computer Vision and Graphics, 2006, 32(1): 528-533

[9] Awrangjeb M, Lu G J. Robust image corner detection based on the chord-to-point distance accumulation technique [J]. IEEE Transactions on Multimedia, 2008, 10(6): 1059-1072

[10] Awrangjeb M, Lu G J, Fraser C S. A fast corner detector based on the chord-to-point distance accumulation technique [C] // 2009 Digital Image Computing: Techniques and Applications. Melbourne, Australia; IEEE, 2009: 519-525

[11] 王万良,金亦挺,赵燕伟,等.点到弦距离累加的自适应角点检测[J]. 中国图象图形学报,2012,17(12):1500-1508

[12] Awrangjeb M, Lu G J, Fraser C S. Performance comparisons of contour-based corner detectors [J]. IEEE Transactions on Image Processing, 2012, 21(9): 4167-4179

[13] Han J H, Poston T. Chord-to-point distance accumulation and planar curvature: A new approach to discrete curvature [J]. Pattern Recognition Letters, 2001, 22(10): 1133-1144

[14] Awrangjeb M, Lu G J. An Improved curvature scale-space corner detector and a robust corner matching approach for transformed image identification [J]. IEEE Transactions on Image Processing, 2008, 17(12): 2425-2441