

基于图像协方差无关的增量特征提取方法研究

王肖锋^{①②} 孙明月^① 葛为民^{*①②}

^①(天津理工大学天津市先进机电系统设计与智能控制重点实验室 天津 300384)

^②(天津理工大学机电工程国家级实验教学示范中心 天津 300384)

摘要: 针对2维主成分分析(2DPCA)算法无法实现在线特征提取及无法体现完整数据结构信息等问题, 该文提出一种基于图像协方差无关的增量式2DPCA(I2DPCA)算法。该算法无需对图像协方差矩阵进行特征值分解奇异值分解, 复杂度将大为降低, 提高了特征提取速度。针对I2DPCA仅提取了横向特征的问题, 又提出一种增量式行列顺序2DPCA(IRC2DPCA)算法, 该算法对I2DPCA的特征矩阵再次进行纵向特征提取, 保留了图像的横向与纵向结构信息, 实现了行列两个方向上的特征提取与数据降维。最后, 以自建的物块数据集、通用的ORL和Yale人脸数据集分别进行对比实验, 结果表明, 该文算法在收敛率、分类率及复杂度等性能方面均得到了显著提高, 其收敛率达到99%以上, 分类率可达97.6%, 平均处理速度为29 帧/s, 能够满足增量特征提取的实时处理需求。

关键词: 模式识别; 协方差无关; 特征提取; 增量学习; 2维主成分分析

中图分类号: TP391.41

文献标识码: A

文章编号: 1009-5896(2019)11-2768-09

DOI: [10.11999/JEIT181138](https://doi.org/10.11999/JEIT181138)

An Incremental Feature Extraction Method without Estimating Image Covariance Matrix

WANG Xiaofeng^{①②} SUN Mingyue^① GE Weimin^{①②}

^①(*Tianjin Key Laboratory for Advanced Mechatronical System Design and Intelligent Control, Tianjin University of Technology, Tianjin 300384, China*)

^②(*National Experimental Teaching Demonstration Center of Electromechanical Engineering, Tianjin University of Technology, Tianjin 300384, China*)

Abstract: To solve the problems that Two-Dimensional Principal Component Analysis (2DPCA) can not implement the on-line feature extraction and can not represent the complete structure information, an Incremental 2DPCA (I2DPCA) without estimating covariance matrices is presented by an iterative estimation method, not to deal with the image covariance matrices by the eigenvalue decomposition or the singular value decomposition. The complexity will be greatly reduced and the on-line feature extraction speed can be improved. The proposed I2DPCA can only extract the horizontal features, and thus another Incremental Row-Column 2DPCA (IRC2DPCA) is proposed to incrementally extract the longitudinal ones from the feature matrices of the I2DPCA. The IRC2DPCA can preserve the horizontal and longitudinal features and implement the dimensionality reduction in both row and column directions. Finally, a series of experiments are carried out with the self-built block dataset, ORL and Yale face datasets, respectively. The results show that the proposed algorithms have significantly improved the performances of the convergence rate, the classification rate and the complexity. The convergence rate is over 99%, the classification rate can reach 97.6% and the average processing speed is about 29 frames per second, and it can meet the on-line feature extraction requirements for incremental learning.

Key words: Pattern recognition; Covariance-free; Feature extraction; Incremental learning; Two-Dimensional Principal Component Analysis (2DPCA)

收稿日期: 2018-12-10; 改回日期: 2019-05-06; 网络出版: 2019-05-22

*通信作者: 葛为民 geweimin@tjut.edu.cn

基金项目: 国家重点研发计划(2017YFB1303304), 天津市科技计划重大专项(17ZXZNGX00110), 天津市自然科学基金重点基金(16JCZDJC30400)

Foundation Items: The National Key R & D Plan of China (2017YFB1303304), The Tianjin Science and Technology Planned Key Project (17ZXZNGX00110), The Tianjin Natural Science Key Foundation (16JCZDJC30400)

1 引言

当前模式识别领域里最具挑战的任务之一就是处理海量的繁杂数据，其目的是不断提取嵌入在这些数据中的内在信息，为后续的机器学习和数据挖掘提供低维的内在数据表征，进而满足大数据的实时在线处理要求。近年来，特征提取研究已在人脸识别^[1]、语音识别^[2]、字符识别^[3]、姿势识别^[4]及雷达目标微动检测^[5]等众多领域得到了广泛应用。

传统特征提取方法通常基于批量处理方式，主要有：主成分分析(Principal Component Analysis, PCA)、线性判别分析(Linear Discriminative Analysis, LDA)及独立成分分析(Independent Component Analysis, ICA)等^[6]。其中PCA作为一种被广泛使用的特征提取与数据降维方法，目的是寻求一组单位正交基向量(特征主成分)，以满足投影空间中数据方差最大^[7]。就处理速度而言，针对2维图像矩阵进行特征提取研究得以发展。Yang等人^[8]最早提出了2维主成分分析(2-Dimension PCA, 2DPCA)方法。随后，相关的改正算法包括双向2DPCA(two-Directional 2DPCA, 2D²PCA)^[9]及双向PCA(Bi-Directional PCA, BDPCA)^[10]得到不断提出。Yang等人^[11]则提出了行列2DPCA(Row-Column 2DPCA, RC2DPCA)，在特征提取性能上得到进一步提升。近年来，2DPCA相关研究正延伸到鲁棒子空间学习领域。Gao等人^[12]提出了Angle-2DPCA方法，在满足数据方差最大的基础上采用了F函数作为距离度量准则，提高了鲁棒性能。而Zhou等人^[13]则在Angle-2DPCA的基础上提出了双向Angle-2DPCA(Bilateral Angle 2DPCA, BA2DPCA)，从行列两个方向进行特征提取，在实现数据降维的同时获得了较高的鲁棒性能。上述方法均采用批量方式，如新增样本或新增类别投影到现有特征空间上，则需重新训练整个样本，对大样本数据而言将影响其实时性。

增量特征提取方法能够融合新样本或新类型的特征，尤其在大样本数据涌现时或新的分类目标进入时，增量方法具有明显的自适应性优势。增量PCA(Incremental PCA, IPCA)能随样本的增加更新特征主成分，并不断适应新增样本。IPCA更新方式主要有特征值分解、奇异值分解及协方差矩阵无关3类^[14]。前2类都是基于图像协方差矩阵来实现的，其复杂度达到 $O(nk^3)$ ， n 为样本数， k 为特征主成分数，其计算量较大，难以满足实时增量处理需求。Weng等人^[15]提出的直观协方差无关IPCA(Candid Covariance-free IPCA, CCIPCA)，能够快速估计图像矩阵的主成分，具有较好的收敛效

果。王肖锋等人^[16]在CCIPCA的基础上提出了一种含均值差向量更新的泛化CCIPCA算法(Generalized CCIPCA, GCCIPCA)，拓展了算法的适用范围。上述2种均为协方差无关方法，无需对协方差矩阵进行特征值分解或奇异值分解，但仍需展开成1维的列向量来估计特征主成分。因此，其矩阵维数仍达到 $pq \times pq$ ，计算量依然较大，难以满足实时性需求^[17]。Ren等人^[18]提出了BDPCA算法的增量方法，基于奇异值分解解决行列方向协方差矩阵的特征主成分增量计算问题，整个分解过程的计算量依然较大。曹向海等人^[19]将CCIPCA算法改写成幂法形式，提出了一种基于幂法的增量BDPCA算法，可以获得高精度特征向量的估计值，其特征维数较高。因此，基于协方差无关的增量特征提取方法需要同时考虑特征矩阵维数少、自适应强及实时性等需求。

本文借鉴人类后天的学习方式，首先提出了一种基于协方差无关的增量式2DPCA算法(Incremental 2DPCA, I2DPCA)，该算法采用增量递归方式，无需先将图像矩阵转为1维向量，也无需对图像协方差矩阵直接计算，有效降低算法的处理维数和复杂度，提高了处理速度。为了完整提取图像矩阵的特征空间信息，在I2DPCA基础上又提出了一种增量式行列顺序的2DPCA算法(Incremental Row-Column 2DPCA, IRC2DPCA)，该算法不仅具有增量学习能力，而且能够减少特征矩阵的维数，降低特征提取与分类识别的复杂度。最后，分别以自建的物块数据集、通用的ORL和Yale人脸数据集作为实验样本，进行收敛性、分类率、计算时间及所需内存等性能的实验对比与分析。

2 I2DPCA算法

2.1 2DPCA算法

Yang等人^[8]提出的批量2DPCA算法，设图像样本矩阵为 $\mathbf{X}'(i) \in R^{p \times q}$ ($i = 1, 2, \dots, n$)，则在行方向上针对2维图像样本构造的协方差矩阵为

$$\mathbf{S}_r = \frac{1}{n} \sum_{i=1}^n [\mathbf{X}'(i) - \bar{\mathbf{X}}(n)]^T [\mathbf{X}'(i) - \bar{\mathbf{X}}(n)] \quad (1)$$

其中， $\mathbf{S}_r \in R^{q \times q}$ ， $\bar{\mathbf{X}}(n) = 1/n \sum_{i=1}^n \mathbf{X}'(i)$ 为所有图像样本矩阵的均值， n 为样本数。通过特征值分解方法可求得协方差矩阵 \mathbf{S}_r 的前 k_r 个最大特征值所对应的特征向量，构成投影矩阵为

$$\mathbf{W}_r = [\mathbf{w}_{r1}, \mathbf{w}_{r2}, \dots, \mathbf{w}_{rk_r}] \quad (2)$$

其中， $\mathbf{W}_r \in R^{q \times k_r}$ ，满足 $\arg \max_{\mathbf{W}_r^T \mathbf{W}_r = \mathbf{I}} \text{tr} \sum_{i=1}^n (\mathbf{W}_r \mathbf{S}_r$

\mathbf{W}_r^T), 且 $\{w_{rj}\}_{j=1}^{k_r}$ 构成所求 k_r 维线性子空间的标准正交基。

将图像样本矩阵 $\mathbf{X}'(i)$ 直接投影到 \mathbf{W}_r 上, 得到 $p \times k_r$ 大小特征矩阵为

$$\mathbf{Y}(i) = \mathbf{X}'(i) \mathbf{W}_r \quad (3)$$

2DPCA作为一种2维的批量处理方法, 当新增样本或类别时, 需对所有样本数据重新计算协方差矩阵求取特征向量, 其计算量将极大, 因此, 2DPCA不适用于连续样本数据或视频流的实时特征提取。

2.2 I2DPCA算法推导

针对2DPCA算法的批量处理方式及无法满足实时性等问题, 本文提出了一种图像协方差无关的I2DPCA算法, 用于连续样本数据的增量学习。

将 $\mathbf{X}(i) = \mathbf{X}'(i) - \bar{\mathbf{X}}(n)$ 代入式(1), 则协方差矩阵重新改写为

$$\mathbf{S}_r = \frac{1}{n} \sum_{i=1}^n \mathbf{X}^T(i) \mathbf{X}(i) \quad (4)$$

其中, $\mathbf{X}(i)$ 为图像样本的中心化矩阵, 一般满足高斯分布或其它未知的样本分布。式(4)在后续的增量递归估计中并不直接参与计算, 而仅作为递归公式推导的中间过程。

为了避免对图像协方差矩阵直接进行特征值和特征向量求解, 定义特征主成分估计向量为

$$\mathbf{v}_r = \lambda_r \mathbf{a}_r = \mathbf{S}_r \mathbf{a}_r \quad (5)$$

其中, \mathbf{a}_r 为协方差矩阵 \mathbf{S}_r 的特征向量, λ_r 为相应的特征值。

将式(4)代入式(5), 则得

$$\mathbf{v}_r(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{X}^T(i) \mathbf{X}(i) \mathbf{a}_r(i) \quad (6)$$

其中, $\mathbf{v}_r(n)$ 是 \mathbf{v}_r 的第 n 步估计向量。通过 $\lambda_r = \|\mathbf{v}_r\|$ 和 $\mathbf{a}_r = \mathbf{v}_r / \|\mathbf{v}_r\|$, 可求得估计的特征值及对应的特征向量, 从而避免了对协方差矩阵 \mathbf{S}_r 的直接计算。

近似估计 $\mathbf{a}_r(n) \approx \mathbf{a}_r(n-1) = \mathbf{v}_r(n-1) / \|\mathbf{v}_r(n-1)\|$, 将其代入式(6)中, 得到 $\mathbf{v}_r(n)$ 的增量表达式为

$$\mathbf{v}_r(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{X}^T(i) \mathbf{X}(i) \frac{\mathbf{v}_r(i-1)}{\|\mathbf{v}_r(i-1)\|} \quad (7)$$

将其改写成增量迭代形式并引入权重系数为

$$\mathbf{v}_r(n) = \frac{n-1-l}{n} \mathbf{v}_r(n-1) + \frac{1+l}{n} \cdot \mathbf{X}^T(n) \mathbf{X}(n) \frac{\mathbf{v}_r(n-1)}{\|\mathbf{v}_r(n-1)\|} \quad (8)$$

其中, l 为权重系数, 主要用来调整当前新增中心

化图像样本 $\mathbf{X}(n)$ 和历史估计向量 $\mathbf{v}_r(n-1)$ 两者的权重。在递归过程中, 每输入一个新的图像样本数据 $\mathbf{X}'(n)$, 需先对其进行中心化处理, 而样本均值 $\bar{\mathbf{X}}(n)$ 也需随之更新。其样本均值的增量迭代形式可表示为

$$\bar{\mathbf{X}}(n) = \frac{n-1}{n} \bar{\mathbf{X}}(n-1) + \frac{1}{n} \mathbf{X}'(n) \quad (9)$$

式(8)只是估算出协方差矩阵 \mathbf{S}_r 的最大(第1阶)特征主成分所对应的估计向量。如计算其它高阶特征主成分相应的估计向量时, 需将第 n 个样本的第 i 个特征向量的输入 $\mathbf{X}_i(n)$, 减去其在第 i 个特征向量估计值 $\mathbf{v}_{ri}(n)$ 上的投影所得到的残差作为第 $i+1$ 个特征向量的输入, 可得到

$$\mathbf{X}_{i+1}(n) = \mathbf{X}_i(n) - \mathbf{X}_i(n) \frac{\mathbf{v}_{ri}(n)}{\|\mathbf{v}_{ri}(n)\|} \frac{\mathbf{v}_{ri}^T(n)}{\|\mathbf{v}_{ri}(n)\|} \quad (10)$$

其中, $\mathbf{X}_{i+1}(n)$ 为第 n 个样本的第 $i+1$ 阶特征向量的输入, 初始时 $\mathbf{X}_1(n) = \mathbf{X}(n)$ 。由式(8)可得到高阶特征主成分估计向量为

$$\mathbf{v}_{ri}(n) = \frac{n-1-l}{n} \mathbf{v}_{ri}(n-1) + \frac{1+l}{n} \cdot \mathbf{X}_i^T(n) \mathbf{X}_i(n) \frac{\mathbf{v}_{ri}(n-1)}{\|\mathbf{v}_{ri}(n-1)\|} \quad (11)$$

在计算高阶特征主成分的估计向量时, 同2DPCA一样能够保证各个估计特征向量之间正交性, 避免其它复杂的正交化处理。当新增一个 $\mathbf{X}(n)$ 时, 先通过式(8)对最大特征主成分估计向量进行更新, 之后由式(10)得到样本数据与最大特征向量的残差, 以此利用式(11)再对第2阶特征主成分估计向量进行更新, 依次类推, 进行迭代。迭代出前 k_r 个高阶特征主成分估计向量, 进而求得高阶特征向量。通过迭代估计得到的前 k_r 个高阶特征向量组成 $q \times k_r$ 维投影矩阵为

$$\hat{\mathbf{W}}_r = [\hat{\mathbf{w}}_{r1}, \hat{\mathbf{w}}_{r2}, \dots, \hat{\mathbf{w}}_{rk_r}] \quad (12)$$

同2DPCA一样, 也可以将图像样本矩阵 $\mathbf{X}'(i)$ 投影到 $\hat{\mathbf{W}}_r$ 上, 得到 $p \times k_r$ 的估计特征矩阵为

$$\hat{\mathbf{Y}}(i) = \mathbf{X}'(i) \hat{\mathbf{W}}_r \quad (13)$$

I2DPCA不用对协方差矩阵求解特征向量, 而是采用递归迭代的计算方式对其进行估算。其I2DPCA只对图像样本矩阵提取了横向特征, 实现了列方向上的数据降维。

3 IRC2DPCA算法

I2DPCA忽略了图像的纵向特征, 无法完整体现原图像空间的数据结构信息。因此, 在I2DPCA的基础上, 对其投影后的特征矩阵 $\hat{\mathbf{Y}}(i)$ 再进行列

方向上的特征提取，使其获得的特征矩阵兼具有行列两个方向上的结构特征。

3.1 IRC2DPCA算法推导

将I2DPCA所提取的特征矩阵 $\hat{\mathbf{Y}}(i)$ 重新作为训练样本矩阵，再进行列方向上的特征提取，其行方向上协方差矩阵可表示为

$$\mathbf{S}_c = \frac{1}{n} \sum_{i=1}^n \mathbf{Y}(i) \mathbf{Y}^T(i) \quad (14)$$

其中， $\mathbf{S}_c \in R^{p \times p}$ ， $\hat{\mathbf{Y}}(i) = \mathbf{Y}(i) - \bar{\mathbf{Y}}(n)$ ，且 $\bar{\mathbf{Y}}(n) = 1/n \sum_{i=1}^n \hat{\mathbf{Y}}(i)$ 。

同理，可以得到增量迭代形式为

$$\begin{aligned} \mathbf{v}_{ci}(n) = & \frac{n-1-l}{n} \mathbf{v}_{ci}(n-1) + \frac{1+l}{n} \\ & \cdot \mathbf{Y}_{ci}(n) \mathbf{Y}_{ci}^T(n) \frac{\mathbf{v}_{ci}(n-1)}{\|\mathbf{v}_{ci}(n-1)\|} \end{aligned} \quad (15)$$

其它高阶特征向量可采用类似I2DPCA的方式得到

$$\mathbf{Y}_{i+1}(n) = \mathbf{Y}_i(n) - \frac{\mathbf{v}_{ci}(n)}{\|\mathbf{v}_{ci}(n)\|} \frac{\mathbf{v}_{ci}^T(n)}{\|\mathbf{v}_{ci}^T(n)\|} \mathbf{Y}_i(n) \quad (16)$$

其中， $\mathbf{Y}_{i+1}(n)$ 为第 n 个样本的第 $i+1$ 个特征向量的输入，初始时 $\mathbf{Y}_1(n) = \mathbf{Y}(n)$ 。同理迭代计算出其前 k_c 个高阶特征向量，组成 $p \times k_c$ 投影矩阵为

$$\hat{\mathbf{W}}_c = [\hat{\mathbf{w}}_{c1}, \hat{\mathbf{w}}_{c2}, \dots, \hat{\mathbf{w}}_{ck_c}] \quad (17)$$

将原特征矩阵 $\hat{\mathbf{Y}}(i)$ 投影到投影矩阵 $\hat{\mathbf{W}}_c$ 上，得到新的 $k_c \times k_r$ 特征矩阵为

$$\begin{aligned} \mathbf{R} &= \hat{\mathbf{W}}_c^T \hat{\mathbf{Y}}(i) \\ &= \hat{\mathbf{W}}_c^T \mathbf{X}'(i) \hat{\mathbf{W}}_r \end{aligned} \quad (18)$$

3.2 复杂度与收敛性分析

I2DPCA时间复杂度为 $O(nk_r q^2)$ ，而2DPCA为 $O(nq^3 + npq)$ ，因此，I2DPCA计算量远小于2DPCA。I2DPCA每次仅需保存新增图像样本，其空间复杂度与样本数无关，仅为 $O(pq)$ ，远小于2DPCA的 $O(npq)$ 。而IRC2DPCA实质是按照行列顺序进行2次增量特征提取，能够满足连续样本数据或实时视频流数据的增量学习。将其图像样本行列信息进行融合，其特征矩阵维数为 $k_c \times k_r$ ，远小于2DPCA和I2DPCA算法所提取的 $p \times k_r$ ，一般满足 $k_c \ll p$ 和 $k_r \ll q$ ，有效降低了特征维数。从时间复杂度看，IRC2DPCA为 $O(nk_r q^2 + nk_c p^2)$ ，其计算量要大于I2DPCA，而空间复杂度与I2DPCA完全一样，依然是 $O(pq)$ 。

I2DPCA与IRC2DPCA有效与否的关键是其估算的特征向量的收敛性，即经过若干图像样本更新

之后，估算的特征向量能否收敛到其对应的真实值。收敛性主要受样本维数比 (n/d) 的影响，其值越大，越易收敛。当样本数为 n 时，I2DPCA的样本维数比为 $n/(p \times q)$ ，而IRC2DPCA的样本维数比为 $n/(p \times k_r)$ ，由于 $k_r \ll q$ ，故IRC2DPCA的样本维数比大于I2DPCA，故其收敛性将优于I2DPCA。

总之，IRC2DPCA在I2DPCA的基础上，对其投影后的特征矩阵再进行列方向上的特征提取，保留了图像中横向与纵向的结构信息。IRC2DPCA特征提取的维数仅为 $k_c \times k_r$ ，其时间和空间复杂度仅为 $O(nk_r q^2 + nk_c p^2)$ 和 $O(pq)$ ，并且其增量递归的计算方式能够优化现有特征矩阵并适应新增样本的特征信息，因此，IRC2DPCA兼具有特征提取维数少、自适应强及复杂度低等优势。

4 实验结果与分析

为了验证所提算法的有效性及通用性，选用自建物块数据集、通用的ORL和Yale人脸数据集分别作为实验样本，进行收敛率、分类率及复杂度等对比实验。物块数据集包括圆柱体、三棱柱、立方体和长方体共4类物块。每类物块各选取不同位姿的500幅图像，共2000幅图像，分辨率为 120×120 ，实验前均进行了灰度处理。图1展示了每类物块的其中任意10幅。ORL数据集由40个人脸图像组成，每个人10幅，共400幅图像样本，包含不同的姿势、表情和面部细节的人脸图像，分辨率均为 112×92 。图2展示了其中任意4人的10幅图像。而Yale数据集包含15位志愿者，每人11幅图像共165张图像，分辨率为 100×100 ，包含光照、表情和姿态的变化。图3展示了其中任意4位志愿者的11幅图像。为了验证算法在大样本数据下的性能，对各数据集的所有




图1 部分物块样本图像



图2 部分ORL人脸样本图像



图3 部分Yale人脸样本图像

样本进行重复输入, 设重复次数为 m 。实验环境为: CPU为i5、内存为2 GB、主频为2.5 GHz的64位Windows7硬件环境和VS2010+Opencv2.4.10的软件环境。

4.1 收敛性实验

为了验证所提出的算法对批量算法特征向量递归估算的效果, 进行收敛率实验。定义 w_i 为2DPCA或RC2DPCA批量算法得到的特征向量作为真实值, 定义 \hat{w}_i 为I2DPCA或IRC2DPCA估算的特征向量。收敛率为估计值与对应的真实值内积的绝对值 $|\hat{w}_i \cdot w_i|$ 。为了增加输入样本数, 对物块数据集所有样本循环输入多次, 得到其收敛率如图4所示。可以看出, 与I2DPCA相比, IRC2DPCA的前8个特征向量收敛性优势明显。在循环输入10次后, IRC2DPCA前8个特征向量的收敛率均超到

99%, 而I2DPCA在经过10次循环输入后, 第8个特征向量收敛率仅为94%。因此, IRC2DPCA经过行列方向上两次特征提取后, 加快了特征向量收敛速度, 提高了其收敛率。

为了验证算法在不同数据集下对特征向量收敛率的影响, IRC2DPCA和I2DPCA特征向量收敛率的均值及标准差如表1所示。可以看出, 随着循环输入次数的增加, 其收敛率均值也相应增加。因此, 训练样本愈多, 两种增量算法的估计特征向量愈接近真实特征向量。在不同数据集下, IRC2DPCA收敛率均值明显优于I2DPCA, 且其标准差更小。此外, IRC2DPCA在不同数据集下各特征向量收敛性均值变化不大, 具有一定的通用性。因此, 所提出的算法可用于其它模式识别领域内的特征提取与数据降维。

4.2 分类率实验

为了从不同角度测试和比较本文所提出的算法性能, 对物块数据集、ORL及Yale人脸数据集分别进行分类率实验, 分类算法采用K-近邻算法(K-Nearest Neighbor, KNN)。通过多次实验寻求每种算法最佳分类率时, 其特征维数总在一定的特征维数附近左右波动, 且波动幅度很小。因此, 本实验中, 针对每种算法选用最佳分类率所对应的特征维

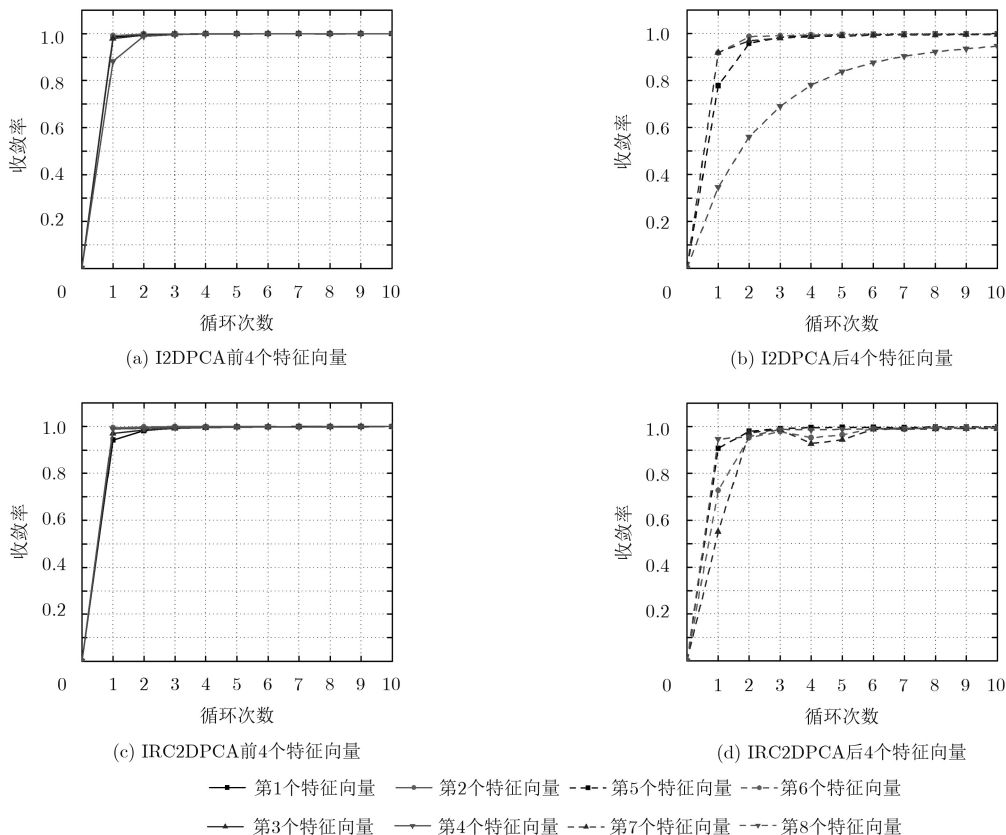


图4 物块数据集循环多次特征向量的收敛率

数进行训练和测试^[20]。针对不同数据集下的训练样本数进行分类测试时，随机从每类对象样本中抽取 L 个样本作为训练学习，该类对象余下的样本用作分类测试。

表2—表4给出了不同算法在3个数据集中获得的最佳分类率，括号内为算法相应的特征维数。从

中可以看出，随着训练样本数的增加，在物块数据集下8种算法的分类率均呈上升趋势，随着样本增加，IRC2DPCA的分类率均高于其它7种算法，其最高分类率可达97.6%。其分类率性能在人脸数据集下并不明显，这是受样本数少所致，随着样本数继续增加，其分类率的优势将愈加明显。与I2DPCA

表 1 不同数据集下特征向量收敛率的均值及标准差

数据集	输入次数	I2DPCA(均值/标准差)		IRC2DPCA(均值/标准差)	
		前4个特征向量	后4个特征向量	前4个特征向量	后4个特征向量
物块	$m = 2$	0.99442/0.00361	0.86836/0.17826	0.98964/0.00573	0.96564/0.01135
	$m = 5$	0.99924/0.00041	0.95478/0.15818	0.99824/0.00101	0.97302/0.01020
	$m = 10$	0.99981/0.00010	0.98453/0.02225	0.99950/0.00030	0.99495/0.00322
ORL	$m = 2$	0.99991/0.00004	0.89400/0.06763	0.99753/0.00203	0.98175/0.01027
	$m = 5$	0.99997/0.00002	0.91620/0.05154	0.99951/0.00037	0.99441/0.00231
	$m = 10$	0.99998/0.00001	0.92833/0.05163	0.99986/0.00010	0.99755/0.00074
Yale	$m = 2$	0.93732/0.07244	0.96069/0.03026	0.99602/0.00441	0.98308/0.00659
	$m = 5$	0.96001/0.04678	0.98261/0.01609	0.99924/0.00074	0.99528/0.00140
	$m = 10$	0.97283/0.03180	0.99041/0.00970	0.99975/0.00024	0.99793/0.00088

表 2 物块数据集的最佳分类率

每类训练样本数	2DPCA (120×4) ^[8]	RC2DPCA (8×8) ^[11]	Angle-2DPCA (120×4) ^[12]	BA2DPCA (8×8) ^[13]	BDPCA (8×8) ^[10]	IBDPCA (8×8) ^[17]	I2DPCA (120×4)	IRC2DPCA (8×8)
$L=10$	0.933	0.927	0.922	0.931	0.930	0.930	0.926	0.922
$L=25$	0.957	0.960	0.958	0.961	0.959	0.959	0.962	0.968
$L=50$	0.959	0.961	0.961	0.961	0.961	0.967	0.962	0.972
$L=75$	0.954	0.957	0.954	0.957	0.958	0.956	0.955	0.958
$L=100$	0.966	0.963	0.966	0.964	0.963	0.973	0.971	0.976

表 3 ORL数据集的最佳分类率

每类训练样本数	2DPCA (112×4) ^[8]	RC2DPCA (8×8) ^[11]	Angle-2DPCA (112×4) ^[12]	BA2DPCA (8×8) ^[13]	BDPCA (8×8) ^[10]	IBDPCA (8×8) ^[17]	I2DPCA (112×4)	IRC2DPCA (8×8)
$L=1$	0.744	0.728	0.742	0.725	0.728	0.708	0.736	0.717
$L=2$	0.850	0.844	0.850	0.847	0.847	0.844	0.847	0.841
$L=3$	0.868	0.857	0.868	0.861	0.861	0.846	0.864	0.857
$L=4$	0.888	0.896	0.888	0.892	0.904	0.904	0.883	0.900
$L=5$	0.905	0.905	0.905	0.905	0.915	0.915	0.905	0.925

表 4 Yale数据集的最佳分类率

每类训练样本数	2DPCA (100×4) ^[8]	RC2DPCA (8×8) ^[11]	Angle-2DPCA (100×4) ^[12]	BA2DPCA (8×8) ^[13]	BDPCA (8×8) ^[10]	IBDPCA (8×8) ^[17]	I2DPCA (100×4)	IRC2DPCA (8×8)
$L=1$	0.560	0.560	0.560	0.560	0.560	0.553	0.573	0.560
$L=2$	0.719	0.733	0.719	0.733	0.741	0.741	0.726	0.726
$L=3$	0.800	0.808	0.792	0.800	0.817	0.825	0.792	0.825
$L=4$	0.857	0.876	0.857	0.876	0.876	0.876	0.857	0.867
$L=5$	0.856	0.889	0.856	0.889	0.889	0.889	0.856	0.889

相比, IRC2DPCA达到最佳分类率时其特征维数仅为 8×8 , 远小于I2DPCA算法的特征维数 120×4 。因此, IRC2DPCA在经过两次特征降维后, 其特征矩阵维数更低, 而其分类率却更高, 说明其内在特征得到了更有效提取。

4.3 复杂度实验

以物块数据集作为实验样本, 以获取最佳分类率所对应的特征维数与表2中各个算法维数一致。当 $m = 3$ 时, 特征提取及分类识别所需时间及内存如表5和表6所示。可以看出, IRC2DPCA的特征提取时间约为I2DPCA的2倍, 这是因为IRC2DPCA在I2DPCA的基础上增加列方向上的特征提取, 导致其计算量的增加。通过表5可求得, I2DPCA特征提取速度可达41 帧/s, 而IRC2DPCA约为22 帧/s, 均能够满足增量的特征提取处理需求。与其它6种算法相比, 所提出的两种增量算法在特征提取速度上优势也较为明显。在特征提取与分类识别总的平均处理速度上, IRC2DPCA与I2DPCA分别达到29 帧/s和49 帧/s, 完全满足数据流的实时处理需求。从表6可以看出, IRC2DPCA在特征提取及分类识别的内存空间上则远优于其它7种算法。随着大量样本的继续增加, 其增量算法在时间和内存上

的复杂度优势也将更趋显著。因此, 所提出的算法尤其适用于大样本数据的增量特征提取。

5 结束语

本文基于2维主成分分析算法, 提出了图像协方差无关的I2DPCA算法和IRC2DPCA算法, 能够用于增量的实时特征提取。通过递归估算的方式实现了行列顺序上的特征提取, 降低了算法的复杂度, 提高了增量学习的处理速度。通过行列方向上的两次提取, 将原始图像的横向特征和纵向特征进行有效融合, 使获取的图像特征信息更加完整体现原数据空间结构, 提高了分类率。理论分析及不同数据集的对比实验分析表明所提出的算法有效。其收敛率可达到99%, 其估计特征向量接近于真实特征向量。当物块图像维数由 120×120 降到 8×8 时, 其最佳分类率仍然可达97.6%, 优于其它算法。IRC2DPCA在计算时间和内存上同样具有明显的优势, 其平均处理速度可达到29帧/s, 能够满足增量的实时处理需求。该算法为增量特征提取研究提供一种更具实用价值的方法, 可直接应用到人脸、场景、文字、语音等其它模式识别领域, 尤其在多维大样本数据特征提取方面将更具优势。

表5 物块数据集处理的所需时间对比(s)

算法	L=10		L=25		L=50		L=75		L=100	
	特征提取	分类识别	特征提取	分类识别	特征提取	分类识别	特征提取	分类识别	特征提取	分类识别
2DPCA(120×4) ^[8]	2.152	5.279	9.568	6.561	32.745	7.990	69.065	9.015	123.779	10.319
RC2DPCA(8×8) ^[11]	2.029	0.941	9.208	1.140	32.630	1.362	66.446	1.335	115.344	1.554
Angle-2DPCA(120×4) ^[12]	4.991	1.097	15.604	1.174	93.28	1.296	67.788	1.471	57.624	1.545
BA2DPCA(8×8) ^[13]	13.117	1.179	14.261	1.190	46.107	1.203	65.105	1.250	48.089	1.233
BDPCA(8×8) ^[10]	2.356	0.933	9.456	0.966	32.988	1.248	67.501	1.414	127.39	1.556
IBDPCA(8×8) ^[17]	11.826	0.868	29.074	1.055	56.778	1.221	86.120	1.408	114.845	1.604
I2DPCA(120×4)	3.103	5.361	7.381	6.225	14.693	7.778	21.938	8.963	29.039	11.181
IRC2DPCA(8×8)	7.159	0.846	17.047	1.043	34.413	1.266	51.577	1.443	65.510	1.669

表6 物块数据集处理的所需内存对比(kB)

算法	L=10		L=25		L=50		L=75		L=100	
	特征提取	分类识别	特征提取	分类识别	特征提取	分类识别	特征提取	分类识别	特征提取	分类识别
2DPCA(120×4) ^[8]	16.658	70.889	37.588	69.935	72.753	68.149	107.941	66.383	143.179	64.622
RC2DPCA(8×8) ^[11]	16.736	11.354	38.199	11.423	73.977	11.227	109.867	10.805	145.764	10.612
Angle-2DPCA(120×4) ^[12]	16.096	48.774	16.096	48.118	16.080	46.768	16.080	45.596	16.080	44.440
BA2DPCA(8×8) ^[13]	16.080	21.642	16.088	21.142	16.104	20.57	16.12	20.504	16.096	20.036
BDPCA(8×8) ^[10]	16.379	11.345	37.040	11.427	71.663	11.243	106.438	10.768	141.160	10.620
IBDPCA(8×8) ^[17]	8.830	11.382	8.499	11.403	8.482	11.218	8.478	10.780	8.486	10.612
I2DPCA(120×4)	8.847	70.897	8.503	69.935	8.486	68.141	8.486	66.301	8.503	64.602
IRC2DPCA(8×8)	8.511	11.350	8.507	11.419	8.486	11.243	8.536	10.797	8.511	10.604

本文研究的增量特征提取其实验采用的图像分辨率最高仅为 120×120 , 低于目前CCD采集的视频流数据的分辨率, 因此, 在一定程度上限制了该算法的实际应用。下一阶段工作重点将利用所提出的算法应用到典型工业领域中, 如针对焊接机器人焊缝表面缺陷实时图像进行特征提取及缺陷识别研究, 解决其应用上的高分辨率问题。此外, 还需考虑特征向量的阶数、重构图像效果与实时性之间的平衡关系。

参 考 文 献

- [1] WANG Hongjuan, HU Jiani, and DENG Weihong. Face feature extraction: a complete review[J]. *IEEE Access*, 2018, 6: 6001–6039. doi: [10.1109/ACCESS.2017.2784842](https://doi.org/10.1109/ACCESS.2017.2784842).
- [2] CHAUDHARY G, SRIVASTAVA S, and BHARDWAJ S. Feature extraction methods for speaker recognition: A review[J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 2017, 31(12): 1–39. doi: [10.1142/S0218001417500410](https://doi.org/10.1142/S0218001417500410).
- [3] SOORA N R and DESHPANDE P S. Review of feature extraction techniques for character recognition[J]. *IETE Journal of Research*, 2018, 64(2): 280–295. doi: [10.1080/03772063.2017.1351323](https://doi.org/10.1080/03772063.2017.1351323).
- [4] NEIVA D H and ZANCHETTIN C. Gesture recognition: A review focusing on sign language in a mobile context[J]. *Expert Systems with Applications*, 2018, 103: 159–183. doi: [10.1016/j.eswa.2018.01.051](https://doi.org/10.1016/j.eswa.2018.01.051).
- [5] 陈小龙, 关键, 于晓涵, 等. 基于短时稀疏时频分布的雷达目标微动特征提取及检测方法[J]. *电子与信息学报*, 2017, 39(5): 1017–1023. doi: [10.11999/JEIT161040](https://doi.org/10.11999/JEIT161040).
CHEN Xiaolong, GUAN Jian, YU Xiaohan, et al. Radar micro-Doppler signature extraction and detection via short-time sparse time-frequency distribution[J]. *Journal of Electronics & Information Technology*, 2017, 39(5): 1017–1023. doi: [10.11999/JEIT161040](https://doi.org/10.11999/JEIT161040).
- [6] ISLAM S, ANAND S, HAMID J, et al. Comparing the performance of linear and nonlinear principal components in the context of high-dimensional genomic data integration[J]. *Statistical Applications in Genetics and Molecular Biology*, 2017, 16(3): 199–216. doi: [10.1515/sagmb-2016-0066](https://doi.org/10.1515/sagmb-2016-0066).
- [7] BRO R and SMILDE A K. Principal component analysis[J]. *Analytical Methods*, 2014, 6(9): 2812–2831. doi: [10.1039/c3ay41907j](https://doi.org/10.1039/c3ay41907j).
- [8] YANG Jian, ZHANG David, FRANGI A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, 26(1): 131–137. doi: [10.1109/TPAMI.2004.1261097](https://doi.org/10.1109/TPAMI.2004.1261097).
- [9] ZHANG Daoqiang and ZHOU Zhihua. (2D)2PCA: Two-directional two-dimensional PCA for efficient face representation and recognition[J]. *Neurocomputing*, 2005, 69(1-3): 224–231. doi: [10.1016/j.neucom.2005.06.004](https://doi.org/10.1016/j.neucom.2005.06.004).
- [10] ZUO Wangmeng, ZHANG David, and WANG Kuanquan. Bidirectional PCA with assembled matrix distance metric for image recognition[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2006, 36(4): 863–872. doi: [10.1109/TSMCB.2006.872274](https://doi.org/10.1109/TSMCB.2006.872274).
- [11] YANG Wankou, SUN Changyin, and RICANEK K. Sequential Row–Column 2DPCA for face recognition[J]. *Neural Computing and Applications*, 2012, 21(7): 1729–1735. doi: [10.1007/s00521-011-0676-5](https://doi.org/10.1007/s00521-011-0676-5).
- [12] GAO Quanxue, MA Lan, LIU Yang, et al. Angle 2DPCA: A new formulation for 2DPCA[J]. *IEEE Transactions on Cybernetics*, 2018, 48(5): 1672–1678. doi: [10.1109/TCYB.2017.2712740](https://doi.org/10.1109/TCYB.2017.2712740).
- [13] ZHOU Shuisheng and ZHANG Danqing. Bilateral angle 2DPCA for face recognition[J]. *IEEE Signal Processing Letters*, 2019, 26(2): 317–321. doi: [10.1109/LSP.2018.2889925](https://doi.org/10.1109/LSP.2018.2889925).
- [14] DIAZ-CHITO K, FERRI F J, and HERNÁNDEZ-SABATÉ A. An overview of incremental feature extraction methods based on linear subspaces[J]. *Knowledge-Based Systems*, 2018, 145: 219–235. doi: [10.1016/j.knosys.2018.01.020](https://doi.org/10.1016/j.knosys.2018.01.020).
- [15] WENG Juyang, ZHANG Yilu, and HWANG Weyshuiuan. Candid covariance-free incremental principal component analysis[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2003, 25(8): 1034–1040. doi: [10.1109/TPAMI.2003.1217609](https://doi.org/10.1109/TPAMI.2003.1217609).
- [16] 王肖锋, 张明路, 刘军. 基于增量式双向主成分分析的机器人感知学习方法研究[J]. *电子与信息学报*, 2018, 40(3): 618–625. doi: [10.11999/JEIT170561](https://doi.org/10.11999/JEIT170561).
WANG Xiaofeng, ZHANG Minglu, and LIU Jun. Robot perceptual learning method based on incremental bidirectional principal component analysis[J]. *Journal of Electronics & Information Technology*, 2018, 40(3): 618–625. doi: [10.11999/JEIT170561](https://doi.org/10.11999/JEIT170561).
- [17] 谢自强, 葛为民, 王肖锋, 等. 发展型机器人实时特征提取方法研究[J]. *机器人*, 2017, 39(2): 189–196. doi: [10.13973/j.cnki.robot.2017.0189](https://doi.org/10.13973/j.cnki.robot.2017.0189).
XIE Ziqiang, GE Weimin, WANG Xiaofeng, et al. Real time feature extraction method of developmental robot[J]. *Robot*, 2017, 39(2): 189–196. doi: [10.13973/j.cnki.robot.2017.0189](https://doi.org/10.13973/j.cnki.robot.2017.0189).
- [18] REN Chuanxian and DAI Daoqing. Incremental learning of

- bidirectional principal components for face recognition[J]. *Pattern Recognition*, 2010, 43(1): 318–330. doi: [10.1016/j.patcog.2009.05.020](https://doi.org/10.1016/j.patcog.2009.05.020).
- [19] 曹向海, 刘宏伟, 吴顺君. 一种有效的增量BDPCA算法[J]. 系统仿真学报, 2008, 20(20): 5530–5533. doi: [10.16182/j.cnki.joss.2008.20.041](https://doi.org/10.16182/j.cnki.joss.2008.20.041).
- CAO Xianghai, LIU Hongwei, and WU Shunjun. A kind of efficient incremental BDPCA algorithm[J]. *Journal of System Simulation*, 2008, 20(20): 5530–5533. doi: [10.16182/j.cnki.joss.2008.20.041](https://doi.org/10.16182/j.cnki.joss.2008.20.041).
- [20] 文颖, 施鹏飞. 一种基于共同向量结合2DPCA的人脸识别方法[J]. 自动化学报, 2009, 35(2): 202–205. doi: [10.3724/SP.J.1004.2009.00202](https://doi.org/10.3724/SP.J.1004.2009.00202).
- WEN Ying and SHI Pengfei. An approach to face recognition based on common vector and 2DPCA[J]. *Acta Automatica Sinica*, 2009, 35(2): 202–205. doi: [10.3724/SP.J.1004.2009.00202](https://doi.org/10.3724/SP.J.1004.2009.00202).
- 王肖锋: 男, 1977年生, 博士, 讲师, 研究方向为发育机器人和机器学习.
- 孙明月: 女, 1994年生, 硕士生, 研究方向为机器人智能学习.
- 葛为民: 男, 1968年生, 博士, 教授, 研究方向为机器人智能控制.