

基于增量式双向主成分分析的机器人感知学习方法研究

王肖锋^{①②} 张明路^{*①} 刘 军^②

^①(河北工业大学机械工程学院 天津 300130)

^②(天津市先进机电系统设计与智能控制重点实验室 天津 300384)

摘 要: 针对直观协方差无关增量式主成分分析算法(CCIPCA)需要满足零均值高斯分布的问题, 该文提出含均值差向量更新的泛化 CCIPCA 算法(GCCIPCA), 拓展了算法的适用范围。其次, 针对机器人感知学习存在的在线增量计算及有效数据降维等问题, 将 GCCIPCA 的增量思想引入到现有的双向主成分分析算法(BDPCA), 提出基于增量式 BDPCA(IBDPCA)的机器人感知学习方法。该方法直接针对图像矩阵行列方向的类散度矩阵进行迭代估计, 具有一定的泛化能力和快速的增量学习能力, 提高了实时处理速度。最后, 以机器人待抓取物块作为感知对象进行实验, 结果表明所提算法能够满足机器人感知学习的实时处理需求, 相比现有的增量式主成分分析算法, 在收敛率、分类识别率、计算时间及所需内存等性能方面均得到显著提升。

关键词: 机器人感知学习; 增量学习; 数据降维; 直观协方差无关增量式主成分分析; 双向主成分分析

中图分类号: TP391.41

文献标识码: A

文章编号: 1009-5896(2018)03-0618-08

DOI: 10.11999/JEIT170561

Robot Perceptual Learning Method Based on Incremental Bidirectional Principal Component Analysis

WANG Xiaofeng^{①②} ZHANG Minglu^① LIU Jun^②

^①(School of Mechanical Engineering, Hebei University of Technology, Tianjin 300130, China)

^②(Tianjin Key Laboratory of the Design and Intelligent Control of the Advanced Mechatronical System, Tianjin 300384, China)

Abstract: Existing Candid Covariance-free Incremental PCA (CCIPCA) has the limitation of the stable image inherent covariance, and a Generalized CCIPCA (GCCIPCA) with an appended term of the mean difference vector is presented. It can be considered that the CCIPCA is only a special case of the GCCIPCA and can extend the scope of the algorithm. Then, the incremental learning of the proposed GCCIPCA is innovated to the existing Bi-Directional PCA (BDPCA), and the called Incremental BDPCA (IBDPCA) is used for the robot perceptual learning and it can be used to incrementally compute the principal components without estimating the similar scatter matrixes in the row and column directions, which can build up the real-time processing speed greatly. Finally, the blocks grasped by the robot are used as the perceptual objects, and the experimental results demonstrate that the proposed algorithm works well, and the convergence rate, the classification recognition rate, the computation time and the required memory are improved significantly.

Key words: Robot perceptual learning; Incremental learning; Dimension reduction; Candid Covariance-free Incremental PCA (CCIPCA); Bi-Directional PCA (BDPCA)

1 引言

近年来, 机器学习、认知科学及认知神经科学等学科不断发展对智能机器人产生了深远影响。

Weng 等人^[1]首先在《Science》上提出了“自主心智发育”的概念、理论及方法, 指出智能机器人应该像人类智力发育一样, 从无到有, 逐渐学习日益复杂的任务。随后, 学者们相继提出了发育机器人的仿人脑模型、内部动机模型及发育学习模型^[2-4]。在发育机器人的研究中, 机器人在人类指导下对外部感知的对象或环境进行自主分析和学习后, 不断选择或更新相应特征, 进而强化其感知学习能力。机器人感知学习主要分为 3 个步骤: 特征提取、数据降维及语义理解^[5]。特征提取是将视觉传感器数据转换成模式特征, 数据降维是为了减少特征提取的复杂度, 而语义理解是从所提取的特征中识别出物

收稿日期: 2017-06-09; 改回日期: 2017-10-13; 网络出版: 2017-11-23

*通信作者: 张明路 zhangml@hebut.edu.cn

基金项目: 国家自然科学基金(61503119, 61473113), 天津市自然科学基金(15JCYBJC19800, 16JCZDJC30400), 天津市智能制造科技重大专项(15ZXZNGX00090)

Foundation Items: The National Natural Science Foundation of China (61503119, 61473113), The Tianjin Natural Science Foundation (15JCYBJC19800, 16JCZDJC30400), The Tianjin Intelligent Manufacturing and Technology Key Project (15ZXZNGX00090)

体类别或人类行为。

主成分分析(Principal Component Analysis, PCA)作为特征提取和数据降维的主要方法,广泛应用于人脸、物体、场景和行为的特征提取及分类识别^[6]。近年来,PCA算法在机器人运动行为的模拟学习^[7]和机器人感知学习^[5]等领域得到了应用。针对PCA的批量处理方式及协方差矩阵维数过高等问题,Weng等人^[8]提出了直观协方差无关增量式主成分分析算法(Candid Covariance-free Incremental PCA, CCIPCA),它能快速估算出高维图像的特征主成分,具有较好的收敛效果^[9]。Bai等人^[10]将CCIPCA算法应用到共享网络的堵塞路径实时检测和识别。CCIPCA算法需将图像数据依次展开成1维的列向量,其运算量依然较大。随后,2维主成分分析算法(2-Dimension PCA, 2DPCA)及改正算法被相继提出^[11-13],它利用图像矩阵直接生成协方差矩阵,大大减少了运算量。2DPCA算法研究已相对成熟,在物体跟踪^[14]、红外高光谱图像去噪^[15]及雷达信号自动目标识别^[16]等领域得到了实际应用。ZUO等人^[17]针对2DPCA在消除过拟合问题的同时带来的高维数问题,提出了双向主成分分析算法(Bi-Directional PCA, BDPCA)。此后,一些改正BDPCA算法及其应用也相继提出。Sun等人^[18]结合BDPCA和2DPCA两个算法,利用四元数进行识别和重构彩色人脸图像。Yang等人^[19]提出了基于拉普拉斯算子的LBDPCA算法,克服了2DPCA从欧式空间扩展到非欧式空间的缺陷。而Nguyen等人^[20]则将BDPCA直接应用到实时的行人检测。就上述2DPCA和BDPCA而言,如增加新的图像样本到现有的投影子空间,则整个训练样本仍将是批量处理方式,无法满足实时性需求。为了克服上述问题,Ren等人^[21]提出了BDPCA的增量学习方法,利用奇异值分解方法来解决BDPCA行列散度矩阵的增量计算问题,其总的运算量依然较大。因此,应用于机器人感知学习算法需同时满足实时性、自适应性及可扩展性的需求。

本文借鉴人类后天感知学习方式,自主更新数据特征形式,将高维信号转为机器人感知学习的低维数据。针对CCIPCA要求学习样本需满足零均值高斯分布的问题,提出了一个泛化的GCCIPCA算法。该算法拓展了适用范围,相比CCIPCA更具有普适性。同时,针对BDPCA存在的特征奇异值分解运算量较大及批处理方式等问题,将GCCIPCA增量思想引入到现有的BDPCA算法中,提出了一种机器人感知学习方法——增量式双向主成分分析算法(Incremental BDPCA, IBDPKA)。该算法不仅

提高机器人感知的增量学习能力,还能提高其实时处理速度。最后以机器人待抓取物块作为实验感知对象,从特征值的收敛性、分类识别率、计算时间及所需内存等性能方面进行了实验对比与分析。

2 CCIPCA算法及GCCIPCA算法

2.1 CCIPCA算法

Weng等人^[8]提出的CCIPCA算法能够对依次输入的图像样本增量计算其特征主成分。设机器人顺序感知而来的图像样本矩阵 \mathbf{X}'_i 的分辨率为 $p \times q$,先将其转换成1维列向量 \mathbf{x}'_i ,再对前 n 个列向量分别进行中心化处理,则其协方差矩阵表示为

$$\mathbf{A}(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i(n) \mathbf{x}_i^T(n) \quad (1)$$

其中, $\mathbf{x}_i(n)$ 为前 n 个列向量中的第 i 个中心化样本, $i = 1, 2, \dots, n$ 。

为了避免直接对协方差矩阵进行特征值和特征向量的求解,定义一个中间变量 $\mathbf{v}(n)$,满足:

$$\mathbf{v}(n) = \lambda \boldsymbol{\alpha}(n) = \mathbf{A}(n) \boldsymbol{\alpha}(n) \quad (2)$$

其中, $\boldsymbol{\alpha}(n)$ 为 $\mathbf{A}(n)$ 的特征向量, λ 为相应的特征值。

$\mathbf{v}(n)$ 可以通过式(3)求得

$$\mathbf{v}(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i(n) \mathbf{x}_i^T(n) \boldsymbol{\alpha}(n) \quad (3)$$

考虑到 $\lambda = \|\mathbf{v}\|$, $\boldsymbol{\alpha} = \mathbf{v}/\|\mathbf{v}\|$,可以近似选择:

$$\boldsymbol{\alpha}(n) \approx \boldsymbol{\alpha}(n-1) = \mathbf{v}(n-1)/\|\mathbf{v}(n-1)\| \quad (4)$$

结合式(3)和式(4),可得到估计值 $\mathbf{v}(n)$ 的增量递推公式为

$$\mathbf{v}(n) = \frac{n-1}{n} \mathbf{v}(n-1) + \frac{1}{n} \mathbf{x}_n(n) \mathbf{x}_n^T(n) \frac{\mathbf{v}(n-1)}{\|\mathbf{v}(n-1)\|} \quad (5)$$

引入遗忘参数 l 控制式(5)中当前中心化样本 $\mathbf{x}_n(n)$ 和历史估计值 $\mathbf{v}(n-1)$ 的权重,其增量公式可改为

$$\mathbf{v}(n) = \frac{n-1-l}{n} \mathbf{v}(n-1) + \frac{1+l}{n} \mathbf{x}_n(n) \mathbf{x}_n^T(n) \frac{\mathbf{v}(n-1)}{\|\mathbf{v}(n-1)\|} \quad (6)$$

CCIPCA算法能实现对机器人感知的中心化样本 $\mathbf{x}_n(n)$ 的增量迭代计算,能够避免 $\mathbf{A}(n)$ 的特征值和特征向量的直接求解。上述两式中 $\mathbf{x}_n(n) \mathbf{x}_n^T(n)$ 矩阵维数达到 $pq \times pq$,因此,其运算量依然较大。

2.2 GCCIPCA算法推导

针对文献[8]要求输入图像满足近零均值高斯分布的限制条件,本文提出了一个泛化的GCCIPCA算法,以减少输入图像样本内部模型变化对收敛率影响。

第 i 个中心化样本 $\mathbf{x}_i(n)$ 和均值向量 $\bar{\mathbf{x}}(n)$ 分别表

示为

$$\mathbf{x}_i(n) = \mathbf{x}_i' - \bar{\mathbf{x}}(n) \quad (7)$$

$$\bar{\mathbf{x}}(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i' \quad (8)$$

式(7), 式(8)改写成增量形式为

$$\mathbf{x}_i(n) = \mathbf{x}_i(n-1) - \beta \Delta \bar{\mathbf{x}}(m) \quad (9)$$

$$\bar{\mathbf{x}}(n) = \frac{n-1}{n} \bar{\mathbf{x}}(n-1) + \frac{1}{n} \mathbf{x}_n' \quad (10)$$

其中, $\mathbf{x}_i(n-1)$ 为前 $n-1$ 个列向量中的第 i 个中心化样本, $\Delta \bar{\mathbf{x}}(m)$ 为均值差向量, $\Delta \bar{\mathbf{x}}(m) = \bar{\mathbf{x}}(n) - \bar{\mathbf{x}}(n-m)$, β 为均值差向量更新系数, m 为均值差向量更新的样本数。

估计值 $\mathbf{v}(n)$ 增量递推公式可通过式(11)求得

$$\mathbf{v}(n) = \frac{n-1}{n} \mathbf{v}(n-1) + \frac{n-1}{n} \beta^2 \Delta \bar{\mathbf{x}}(m) [\Delta \bar{\mathbf{x}}(m)]^T \cdot \frac{\mathbf{v}(n-1)}{\|\mathbf{v}(n-1)\|} + \frac{1}{n} \mathbf{x}_n(n) \mathbf{x}_n^T(n) \frac{\mathbf{v}(n-1)}{\|\mathbf{v}(n-1)\|} \quad (11)$$

与式(5)稍有不同, 仅增加了与 $\Delta \bar{\mathbf{x}}(m)$ 有关项。当样本均值趋近于零时可认为 $\Delta \bar{\mathbf{x}}(m) = 0$, 或当 $\beta = 0$ 时, 式(11)与式(5)完全等价。因此, CCIPCA 只是 GCCIPCA 的一个特例。根据文献[8]及文献[22]的结论可知, 第 1 主成分的相邻两个估计值 $\mathbf{v}_1(i)$ 和 $\mathbf{v}_1(i+1)$ 均在同一个象限内, 并且在迭代计算过程中 $\mathbf{v}_1(i)$ 与最大估计向量 $\mathbf{v}_1(n)$ 之间的夹角是单调递减的。因此, 根据新输入中心化样本 $\mathbf{x}_n(n)$ 所处的象限位置, 可以确定下一步估计值的收敛性。

式(11)仅解决了第 1 主成分的估算问题, 其它高阶主成分可相应得到:

$$\mathbf{x}_{i+1}(n) = \mathbf{x}_i(n) - \mathbf{x}_i^T(n) \frac{\mathbf{v}_i(n)}{\|\mathbf{v}_i(n)\|} \frac{\mathbf{v}_i^T(n)}{\|\mathbf{v}_i(n)\|} \quad (12)$$

高阶均值差向量采用类似方式也可得到

$$\Delta \bar{\mathbf{x}}_{i+1}(m) = \Delta \bar{\mathbf{x}}_i(m) - [\Delta \bar{\mathbf{x}}_i(m)]^T \frac{\mathbf{v}_i(n)}{\|\mathbf{v}_i(n)\|} \frac{\mathbf{v}_i^T(n)}{\|\mathbf{v}_i(n)\|} \quad (13)$$

这样, 在计算高阶主成分时保证了特征向量之间的正交性, 从而避免了其它复杂的正交化处理。

GCCIPCA 算法不仅能实现对机器人感知的中心化样本的增量迭代计算, 还能对局部历史数据实现均值修正。但式(11)中 $\mathbf{x}_n(n) \mathbf{x}_n^T(n)$ 和 $\Delta \bar{\mathbf{x}}(m) \cdot [\Delta \bar{\mathbf{x}}(m)]^T$ 矩阵维数均达到了 $pq \times pq$, 其运算量将是 CCIPCA 算法的两倍。因此, GCCIPCA 算法能实现一定的泛化能力, 却增加了运算量。

3 BDPKA 算法

文献[17]提出的 BDPKA 算法, 分别对行和列方向进行了数据降维。将图像样本矩阵 \mathbf{X}_i' 分解成 p 个 $1 \times q$ 的行向量, 则行方向总体散度矩阵为

$$\mathbf{S}_r = \frac{1}{np} \sum_{i=1}^n [\mathbf{X}_i' - \bar{\mathbf{X}}(n)]^T [\mathbf{X}_i' - \bar{\mathbf{X}}(n)] \quad (14)$$

其中 $\bar{\mathbf{X}}(n)$ 为图像样本矩阵的均值。取前 k_r 个最大特征值所对应的特征向量组成行方向投影矩阵为

$$\mathbf{W}_r = [w_{r1}, w_{r2}, \dots, w_{rk_r}] \quad (15)$$

同理, 列方向总体散度矩阵及前 k_c 个最大特征值所对应的特征向量组成列方向投影矩阵分别为

$$\mathbf{S}_c = \frac{1}{nq} \sum_{i=1}^n [\mathbf{X}_i' - \bar{\mathbf{X}}(n)] [\mathbf{X}_i' - \bar{\mathbf{X}}(n)]^T \quad (16)$$

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

图像样本矩阵 \mathbf{X}_i' 所对应的特征矩阵为

$$\mathbf{Y} = \mathbf{W}_c^T \mathbf{X}_i' \mathbf{W}_c \quad (18)$$

BDPCA 的特征矩阵维数仅为 $k_c \times k_r$, 因此其运算量要远小于 CCIPCA。但 BDPCA 是 2 维的批量处理计算, 无法满足机器人感知的增量学习需求。BDPCA 对行列方向总体散度矩阵直接求取特征向量, 运算量依然相对较大。

4 基于 IBDPKA 的感知学习方法

机器人感知学习主要负责对感知高维信息自组织提取特征和数据降维, 得到的图像特征向量投影系数用于高层的认知发育。它与后续认知发育协作完成知识的学习、累积和优化, 得出认知识别结果。

4.1 IBDPKA 算法推导

针对 BDPCA 算法批量处理计算及运算量较大的问题, 借鉴 CCIPCA 的增量思想, 本文提出一个基于 GCCIPCA 的 IBDPKA 算法, 用于机器人的实时感知学习。IBDPKA 直接针对图像矩阵行列方向的类散度矩阵进行特征向量的近似估计, 流程如图 1 所示。

对式(14)和式(16)行列方向总体散度矩阵重新改写为

$$\tilde{\mathbf{S}}_r = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_i^T(n) \mathbf{X}_i(n) \quad (19)$$

$$\tilde{\mathbf{S}}_c = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_i(n) \mathbf{X}_i^T(n) \quad (20)$$




图1 IBDPKA 算法特征向量估计计算

式中, $\mathbf{X}_i(n) = \mathbf{X}_i' - \bar{\mathbf{X}}(n)$, $\mathbf{X}_i(n)$ 为图像矩阵的中心化样本, $\tilde{\mathbf{S}}_r$ 和 $\tilde{\mathbf{S}}_c$ 分别为行列方向的类散度矩阵。

为了避免行列方向总体散度矩阵的迭代评估值不至于被减少 $1/p$ 和 $1/q$, 采用行列方向类散度矩阵来估计主成分, 则行列方向估计值分别表示为

$$\mathbf{v}_r(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_i^T(n) \mathbf{X}_i(n) \boldsymbol{\alpha}_{r_i}(n) \quad (21)$$

$$\mathbf{v}_c(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_i(n) \mathbf{X}_i^T(n) \boldsymbol{\alpha}_{c_i}(n) \quad (22)$$

其中, $\boldsymbol{\alpha}_{r_i}(n)$ 和 $\boldsymbol{\alpha}_{c_i}(n)$ 分别为行列方向类散度矩阵的特征向量。式(21)、式(22)写成增量递推形式为

$$\begin{aligned} \mathbf{v}_r(n) &= \frac{n-1}{n} \mathbf{v}_r(n-1) \\ &\quad + \frac{1}{n} \mathbf{X}_n^T(n) \mathbf{X}_n(n) \frac{\mathbf{v}_r(n-1)}{\|\mathbf{v}_r(n-1)\|} \end{aligned} \quad (23)$$

$$\begin{aligned} \mathbf{v}_c(n) &= \frac{n-1}{n} \mathbf{v}_c(n-1) \\ &\quad + \frac{1}{n} \mathbf{X}_n(n) \mathbf{X}_n^T(n) \frac{\mathbf{v}_c(n-1)}{\|\mathbf{v}_c(n-1)\|} \end{aligned} \quad (24)$$

式(23), 式(24)联立式(11), 经推导可得到含均值差向量更新的递推公式为

$$\begin{aligned} \mathbf{v}_r(n) &= \frac{n-1}{n} \mathbf{v}_r(n-1) + \frac{n-1}{n} \beta^2 [\Delta \bar{\mathbf{X}}_r(m)]^T \\ &\quad \cdot \Delta \bar{\mathbf{X}}_r(m) \frac{\mathbf{v}_r(n-1)}{\|\mathbf{v}_r(n-1)\|} \\ &\quad + \frac{1}{n} \mathbf{X}_n^T(n) \mathbf{X}_n(n) \frac{\mathbf{v}_r(n-1)}{\|\mathbf{v}_r(n-1)\|} \end{aligned} \quad (25)$$

$$\begin{aligned} \mathbf{v}_c(n) &= \frac{n-1}{n} \mathbf{v}_c(n-1) + \frac{n-1}{n} \beta^2 \Delta \bar{\mathbf{X}}_c(m) \\ &\quad \cdot [\Delta \bar{\mathbf{X}}_c(m)]^T \frac{\mathbf{v}_c(n-1)}{\|\mathbf{v}_c(n-1)\|} \\ &\quad + \frac{1}{n} \mathbf{X}_n(n) \mathbf{X}_n^T(n) \frac{\mathbf{v}_c(n-1)}{\|\mathbf{v}_c(n-1)\|} \end{aligned} \quad (26)$$

式(25), 式(26)只是针对行列方向最大特征向量进行估计, 其它高阶特征向量可以采用类似 GCCIPCA 方式得到

$$\mathbf{X}_{r(i+1)}(n) = \mathbf{X}_{r_i}(n) - \mathbf{X}_{r_i}(n) \frac{\mathbf{v}_{r_i}(n)}{\|\mathbf{v}_{r_i}(n)\|} \frac{\mathbf{v}_{r_i}^T(n)}{\|\mathbf{v}_{r_i}(n)\|} \quad (27)$$

$$\mathbf{X}_{c(i+1)}(n) = \mathbf{X}_{c_i}(n) - \frac{\mathbf{v}_{c_i}(n)}{\|\mathbf{v}_{c_i}(n)\|} \frac{\mathbf{v}_{c_i}^T(n)}{\|\mathbf{v}_{c_i}(n)\|} \mathbf{X}_{c_i}(n) \quad (28)$$

该算法不用对 $q \times q$ 或 $p \times p$ 的类散度矩阵直接求解特征向量, 其运算量比 BDPCA 更少。IBDPCA 能同时实现局部历史数据的均值更新, 因此, 对样本的内部模型变化适用性较强。此外, 该算法同时对行列方向类散度矩阵进行近似估计, 更完整保留了机器人感知的特征空间信息。总之, IBDPCA 兼

具有 GCCIPCA 的增量感知和 BDPCA 的快速感知两个方面的优势。

4.2 IBDPCA 算法复杂度分析

对于 CCIPCA, 如计算前 k 个特征向量, 则时间复杂度为 $O(nkp^2q^2)$, 仅需要 $O(p^2q^2)$ 内存空间存储当前图像矩阵。而 GCCIPCA 增加了样本均值差向量项, 因此时间复杂度为 $O(2nkp^2q^2)$, 其空间复杂度仍为 $O(p^2q^2)$ 。BDPCA 直接通过特征值分解来实现, 因此时间复杂度为 $O(np^3 + nq^3)$, 而其空间复杂度为 $O(npq)$ 。对于 IBDPCA, 分别针对行列方向提取前 k_r 个和前 k_c 个特征向量, 其时间复杂度为 $O(2nk_r pq + 2nk_c pq)$, 一般满足 $k_r \ll q$ 和 $k_c \ll p$, 而空间复杂度仅为 $O(pq)$, 远少于其它 3 种算法。上述 4 种算法时间和空间复杂度分析见表 1。

表 1 时间与空间复杂度分析

算法	时间复杂度	空间复杂度
CCIPCA	$O(nkp^2q^2)$	$O(p^2q^2)$
GCCIPCA	$O(2nkp^2q^2)$	$O(p^2q^2)$
BDPCA	$O(np^3 + nq^3)$	$O(npq)$
IBDPCA	$O(2nk_r pq + 2nk_c pq)$	$O(pq)$

5 实验结果与分析

为了验证算法的有效性, 选用 4 类物块(蓝色圆柱体、绿色圆柱体、橙色立方体和绿色长方体)进行性能对比实验。每类物块选取不同位姿的 100 幅图像作为样本, 分辨率为 120×120 。图 2 展示了每类物块的其中任意 5 幅。实验前均进行了图像灰度处理, 并随机分成 50 幅训练样本和 50 幅测试样本。为了获得足够多的样本数, 将样本图像循环输入多次进行处理。所有程序运行在 CPU 为 i5、主频为 2.5 GHz、内存为 2 GB 的计算机上, 操作系统为 64 位 Windows7, 编程环境为 VS2010+Opencv2.4.10。相关参数设置为: 遗忘参数 $l = 2$, 均值差向量更新系数 $\beta = 1$, 样本均值更新个数 $m = 5$ 。

5.1 收敛性实验

2DPCA^[11], RC2DPCA^[13] 及 BDPCA^[17] 等算法均为批量处理方法, 不存在收敛性。以蓝色圆柱体作为该实验样本, 对 CCIPCA, GCCIPCA 和 IBDPCA 3 种增量算法进行特征提取及收敛性实验。定义 λ_i 为批处理算法得到的特征值作为真实值, 定义 $\|v_i\|$ 为增量算法的估计值, 收敛率使用比值 $\|v_i\|$





图2 4类物块的部分实验样本


λ_i 进行分析。定义误差率为(估计值-真实值)与真实值的比值,用于分析迭代计算的估计误差。

GCCIPCA 算法所求前 2 个最大特征值与 PCA 算法所求特征值的对比如图 3 所示。可以看出, GCCIPCA 在样本数为 250 时(即循环输入 5 次)前 2 个特征值均接近相应的真实值,其误差率分别为 1.10% 和 7.55%。因此,在进行机器人感知学习时,要求样本数量至少达 250 幅。如对视频流进行感知学习,则要求视频流至少持续 10 s 时间。

GCCIPCA 与 CCIPCA 的收敛率对比如图 4 所示。可以看出,两个算法总体上随样本的增加均趋向收敛。两个算法的第 1 个特征值收敛曲线基本近似,其均值修正效果并不明显,这是由于图 3 中的



(a)第1个特征值



(b)第2个特征值

图3 GCCIPCA 的特征值






图4 GCCIPCA 与 CCIPCA 收敛率对比



(a)第1个特征值



(b)第2个特征值

图5 IBDPCA 行方向上的特征值

第 1 个特征值远大于第 2 个特征值所占主成分所致。当图 4 第 2 个特征值收敛率出现波动时, GCCIPCA 的总体均值修正效果提升了其收敛性能。

IBDPCA 与 BDPCA 行方向上相应特征值的对比如图 5 所示。可以看出,前 2 个特征值在样本数约为 100 时均接近于相应的真实值,其误差率分别为 1.09% 和 4.44%。当样本数为 250 时,其误差率仅为 0.30% 和 1.79%。因此,与 GCCIPCA 相比, IBDPCA 在同样样本数时更接近于真实值。与图 3 相比, IBDPCA 只需更少样本就能接近真实值,且更趋稳定。如对视频流进行感知学习,则视频流仅需持续 4 s 时间。

IBDPCA 的收敛率如图 6 所示。可以看出,前 2 个特征值在行列两个方向均能快速收敛,样本数为 250 时收敛率达到 0.98 以上,并且其收敛曲线几乎完全重叠。在后续实验中,如未做说明均以行方向的性能作为其总体性能。与 CCIPCA 对比,可以看出两个算法在第 1 个特征值的收敛率几乎重叠,而 IBDPCA 的第 2 个特征值收敛率明显更趋稳定,其收敛速度也更快。因此, IBDPCA 总体收敛性能要优于 CCIPCA。

5.2 复杂度实验

以蓝色圆柱体作为实验样本,计算前 2 个最大特征向量所需时间及内存如表 2 和表 3 所示。可以看出, GCCIPCA 计算时间约为 CCIPCA^[8] 的 2 倍,

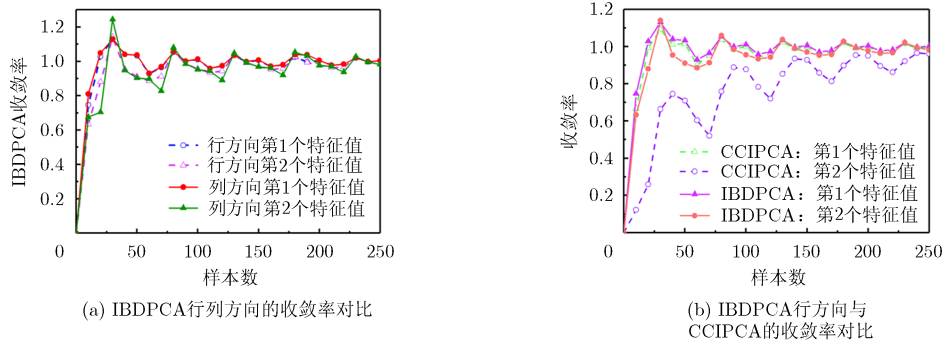


图 6 IBDPCA 行列方向的收敛率

表 2 样本处理所需时间对比(s)

样本数	CCIPCA ^[8]	GCCIPCA	2DPCA ^[11]	RC2DPCA ^[13]	BDPCA ^[17]	IBDPCA
50	112.052	242.397	1.091	1.531	1.934	1.379
100	228.666	470.682	2.975	3.226	4.212	2.956
150	334.689	710.898	4.923	5.750	6.693	4.401
200	445.675	912.162	8.645	9.109	10.062	5.830
250	578.901	1198.490	10.450	12.723	13.665	6.668

表 3 样本处理所需内存对比(MB)

样本数	CCIPCA ^[8]	GCCIPCA	2DPCA ^[11]	RC2DPCA ^[13]	BDPCA ^[17]	IBDPCA
50	834.150	834.621	8.904	9.158	13.496	6.434
100	834.453	834.609	14.778	15.605	25.026	6.463
150	834.453	834.617	20.766	21.774	36.581	6.463
200	834.453	834.617	26.644	27.971	48.136	6.459
250	834.457	834.617	32.497	34.144	59.670	6.455

这是由于均值差向量项导致其运算量的增加。2DPCA^[11], RC2DPCA^[13]及 BDPCA^[17]在时间和内存两方面均优于 CCIPCA 和 GCCIPCA, 但其所需时间和内存会随样本数的增加而增大, 这是由于这 3 种算法均为批处理方法所致。而 IBDPCA 在时间和空间两方面均远优于其它 5 种算法。对于 IBDPCA, 通过表 2 可求得平均处理速度约为 35 帧/s, 大于摄像头视频输入速度 24~26 帧/s, 该算法能够满足机器人感知学习的实时处理需求。

5.3 分类率实验

对于分类率实验, 采用前 2 个最大特征值作为支持向量机的分类属性。分类实验结果如图 7 所示。可以看出, 2DPCA^[11], RC2DPCA^[13]及 BDPCA^[17]3 种批处理算法的分类率均低于其它 3 种增量式处理算法, 这是由于其特征提取精度与样本数无关, 因此其分类率几乎不变。随着样本数的增加, 3 种增量算法分类率最终均十分接近, 但 IBDPCA 要略高于其它两种算法。当样本数为 500 时, 2DPCA 的平

均分类率为 0.69%, RC2DPCA 为 0.66%, BDPCA 为 0.76%, CCIPCA 为 98.47%, GCCIPCA 为 98.40%, IBDPCA 为 98.87%。因此, IBDPCA 算法分类率要远高于其它 3 种批处理算法, 略高于其它两种 1 维的增量处理算法。

6 结束语

本文先提出了基于均值差向量更新的泛化 GCCIPCA 算法, 提高了算法的泛化能力。然后提出了基于 GCCIPCA 的 IBDPCA 算法, 能够提高实时处理速度。理论分析及不同的对比实验分析表明该算法的有效性。该算法的收敛率可达 0.98, 优于其它增量算法。其运算时间及所需内存也远少于其它 5 种算法, 其运算速度可达 35 帧/s, 能满足机器人的增量感知和实时感知需求。IBDPCA 的平均分类率达到 98.87%, 也优于其它主成分分析算法。该算法为机器人实时感知学习研究提供了一种更具实用价值的解决方案, 同时也可应用到人脸、场景




图7 不同算法的分类率对比

等其它模式识别领域。

本文研究的机器人感知学习其实验采用的图像分辨率为 120×120 ，高于目前国际主流人脸数据库的分辨率(如:ORL为 112×92 , FERET为 88×64)，但仍低于摄像头的分辨率，因此不能针对摄像头的视频数据直接进行增量学习。这在一定程度上限制了该方法的自主学习能力，将是下一阶段的研究重点。

参考文献

- [1] WENG J Y, MCCLELLAND J, PENTLAND A, *et al.* Artificial intelligence-autonomous mental development by robots and animals[J]. *Science*, 2001, 291(5504): 599-600. doi: 10.1126/science.291.5504.599.
- [2] GATSOU LIS Y and MCGINNITY T M. Intrinsically motivated learning systems based on biologically-inspired novelty detection[J]. *Robotics and Autonomous Systems*, 2015, 68: 12-20. doi: 10.1016/j.robot.2015.02.006.
- [3] JI ZP and WENG J Y. A developmental where-what network for concurrent and interactive visual attention and recognition[J]. *Robotics and Autonomous Systems*, 2015, 71: 35-48. doi: 10.1016/j.robot.2015.03.004.
- [4] SIGAUD O and DRONIOU A. Towards deep developmental learning[J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2016, 8(2): 99-114. doi: 10.1109/TAMD.2015.2496248.
- [5] YAN H, ANG M H and POO A N. A Survey on perception methods for human-robot interaction in social robots[J]. *International Journal of Social Robotics*, 2014, 6(1): 85-119. doi: 10.1007/s12369-013-0199-6.
- [6] LI Lingjun, LIU Shigang, PENG Yali, *et al.* Overview of principal component analysis algorithm[J]. *Optik-International Journal for Light and Electron Optics*, 2016, 127(9): 3935-3944. doi: 10.1016/j.ijleo.2016.01.033.
- [7] PARK G and KONNO A. Imitation learning framework based on principal component analysis[J]. *Advanced Robotics*, 2015, 29(9): 639-656. doi: 10.1080/01691864.2015.1007084.
- [8] WENG J Y, ZHANG Y L, and HWANG W S. Candid covariance-free incremental principal component analysis[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2003, 25(8): 1034-1040. doi: 10.1109/TPAMI.2003.1217609.
- [9] 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.
- [10] 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.
- [11] BAI H L and CHEN M. CCIPCA-OPCSC: An online method for detecting shared congestion paths[J]. *Computer Networks*, 2012, 56(1): 399-411. doi: 10.1016/j.comnet.2011.09.016.
- [12] WANG J. Generalized 2-D principal component analysis by Lp-Norm for image analysis[J]. *IEEE Transactions on Cybernetics*, 2016, 46(3): 792-803. doi: 10.1109/TCYB.2015.2416274.
- [13] 曹明明, 干宗良, 崔子冠, 等. 基于2D-PCA特征描述的非负权重邻域嵌入人脸超分辨率重建算法[J]. *电子与信息学报*, 2015, 37(4): 777-783. doi: 10.11999/JEIT140739.
- [14] CAO Mingming, GAN Zongliang, CUI Ziguan, *et al.* Novel neighbor embedding face hallucination based on non-negative weights and 2D-PCA feature[J]. *Journal of Electronics & Information Technology*, 2015, 37(4): 777-783. doi: 10.11999/JEIT140739.
- [15] 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.
- [16] XU F, GU G, KONG X, *et al.* Object tracking based on two-dimensional PCA[J]. *Optical Review*, 2016, 23(2): 231-243. doi: 10.1007/s10043-015-0178-2.
- [17] HUANG J, MA Y, MEI X G, *et al.* A hybrid spatial-spectral denoising method for infrared hyperspectral images using 2DPCA[J]. *Infrared Physics & Technology*, 2016, 79: 68-73. doi: 10.1016/j.infrared.2016.09.009.

- [16] PEI J, HUANG Y, HUO W, *et al.* SAR imagery feature extraction using 2DPCA-based two-dimensional neighborhood virtual points discriminant embedding[J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2017, 9(6): 2206–2214. doi: 10.1109/JSTARS.2016.2555938.
- [17] 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.
- [18] SUN Yanfeng, CHEN Shangyou, and YIN Baocai. Color face recognition based on quaternion matrix representation[J]. *Pattern Recognition Letters*, 2011, 32(4): 597–605. doi: 10.1016/j.patrec.2010.11.004.
- [19] YANG Wankou, SUN Changyin, ZHANG Lei, *et al.* Laplacian bidirectional PCA for face recognition[J]. *Neurocomputing*, 2010, 74(1/3): 487–493. doi: 10.1016/j.neucom.2010.08.020.
- [20] NGUYEN T H B and KIM H. Novel and efficient pedestrian detection using bidirectional PCA[J]. *Pattern Recognition*, 2013, 46(8): 2220–2227. doi: 10.1016/j.patcog.2013.01.007.
- [21] 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.
- [22] 余映, 王斌, 张立明. 一种面向数据学习的快速 PCA 算法[J]. *模式识别与人工智能*, 2009, 22(4): 567–573. doi: 10.16451/j.cnki.issn1003-6059.2009.04.003.
- YU Ying, WANG Bin, and ZHANG Liming. A fast data-oriented algorithm for principal component analysis[J]. *Pattern Recognition and Artificial Intelligence*, 2009, 22(4): 567–573. doi: 10.16451/j.cnki.issn1003-6059.2009.04.003.
- 王肖锋: 男, 1977年生, 博士生, 讲师, 研究方向为发育机器人和机器学习.
- 张明路: 男, 1964年生, 博士, 教授, 研究方向为机器视觉、多传感器信息融合及机器人自主智能决策.
- 刘 军: 男, 1961年生, 博士, 教授, 研究方向为转子动力学及转子振动控制.