

有限制的 MFA-ICA 的算法及其在图像特征提取中的应用

刘直芳¹, 游志胜¹, 张继平^{2,3}

(1. 四川大学 计算机学院 图形图像研究所, 四川 成都 610065;

2. 电子科技大学 自动化工程学院, 四川 成都 610054;

3. 成都 95538 部队, 四川 成都 610041)

(liuzhifang7563@163.com)

摘 要:传统的独立成分分析(Independent Component Analysis, ICA)是一种无噪声模型,而实际应用中噪声是存在的。根据多元统计中的因子分析模型,改变其假设条件,从而得到一种有噪声 ICA 模型,对于模型参数,引入平均场近似(Mean Field Approximation, MFA)原理来求解。针对图像特征提取,通过增加对模型参数的一些限制,使其能得到更为独立的图像特征,为图像识别提供更可靠的特征信息,从而大大提高识别率。通过仿真模拟图形以及 ORL 人脸数据进行实验,将传统的独立成分分析算法、无限制的 MFA-ICA 算法以及增加限制条件的 MFA-ICA 算法进行比较,从仿真模拟图形实验结果看,限制的 MFA-ICA 算法能分离出更独立的特征,同时利用限制的 MFA-ICA 算法识别效果明显优于传统 ICA 算法和无限制 MFA-ICA 算法。

关键词:独立成分分析;平均场近似;特征提取

中图分类号: TP317.4 **文献标识码:** A

Restrictive MFC-ICA algorithm and its application in extracting image feature

LIU Zhi-fang¹, YOU Zhi-sheng¹, ZHANG Ji-ping^{2,3}

(1. Institute of Image & Graphic, School of Computer Science, Sichuan University, Chengdu Sichuan 610065, China;

2. School of Automation Engineering, University of Electronic Science and Technology of China, Sichuan Chengdu 610054, China;

3. 95538 Army Chengdu, Chengdu Sichuan 610041, China)

Abstract: A traditional Independent Component Analysis(ICA) is a noise-free model and has some rigorous conditions. However, there are many noises. In this paper, these conditions were changed by the factor analysis in multi-variable statistics and a noisy ICA model was formed. The theory of Mean Field Approximation (MFA) in statistical physics was used to estimate the model parameters. In order to obtain more independent features in feature extraction, some restrictions were added to model parameters, such as non-negative mixing matrices and non-negative source signals. Experiments were done by two different cases that simulated graphics and ORL face databases. The simulated graphics experimental results show this proposed method can extract more independent features than the traditional ICA and the unrestricted MFAICA method do.

Key words: Independent Component Analysis(ICA); Mean Field Approximation(MFA); feature extraction

0 引言

目前在大多数文献中,主要针对无噪声 ICA 模型进行研究的^[1,2],但是现实世界中大多数是存在有噪声的情况,另外,在无噪声 ICA 中,源模型是固定且单模,而实际中的源模型可能是多模态的,因此在寻找独立方向的过程中,一个匹配好的源模是至关重要的,即如果源模型没有得到准确的描述,则源信号将不能分离,所有这些条件都限制无噪声 ICA 模型的应用范围,因此有必要引入有噪声 ICA 模型^[2]。有噪声 ICA 模型本质上是一个概率统计估计问题,但对于具有非高斯特性的源信号,很难直接利用传统的最大似然估计方法来

估计其状态,而目前起源于统计物理学的平均场近似已经广泛用来解决这种状态估计问题^[3-5]。ICA 模型中的混合矩阵和噪声协方差可以直接利用最大似然估计得到,而对于源信号的状态利用平均场近似原理进行估计。

在图像特征提取,特别是人脸识别中,其分离出的特征满足某种条件,即其特征应非负,同时由于各个特征并不同时处于活动状态,具有稀疏性。因此根据图像特征提取的要求,提出通过限制有噪声 ICA 模型中的混合矩阵参数和源信号为非负,来使分离出的特征更具有独立性,从而将更有利于后期的识别处理。本文通过仿真模拟的图形以及 ORL 人脸数据进行实验分析,对于仿真模拟的图形,限制的 MFA-ICA 算

收稿日期:2004-07-08;修订日期:2004-12-18

作者简介:刘直芳(1974-),女,四川达川人,讲师,博士,主要研究方向:图像处理、计算机视觉、模式识别、人工智能、虚拟现实;游志胜(1945-),男,四川成都人,教授,博士生导师,主要研究方向:计算机视觉、图像处理、模式识别、神经网络、雷达模拟系统;张继平(1975-),男,山东平邑人,助理工程师,硕士研究生,主要研究方向:计算机自动化测控、人工智能、模式识别。

法能很好的分离出更独立的特征,为其识别提供更可靠的特征信息,而对于 ORL 人脸数据,其识别结果优于传统 ICA 算法和无限制 ICA 算法的识别结果。

1 独立成分分析模型

独立成分分析是盲信号分离 BSS 的一个重要解决方法,其假设分离出来的源信号是相互独立的,一般认为 ICA 是 PCA 的延伸^[1,2]。由于无噪声模型受到苛刻条件的限制,使得在实际中并不能取得很好的分离效果,而在多元统计分析中,存在另外一种源信号估计算法,即因子分析,但由于因子分析假设源信号为高斯信号,而对于具有高斯特性的信号,不相关就意味着独立的,因此它无法分离源信号。如果我们改变其假设条件使其与传统的 ICA 一致,即假设源信号具有非高斯特性,同时改变其他假设条件,即允许源信号数大于观测信号数,且存在高斯噪声,称满足这些假设的独立成分分析为有噪声独立成分分析模型^[4]。

$$X = AS + \Gamma \quad (1)$$

其中: X 是 $N_m \times N$ 的混合信号, A 是 $N_m \times N_k$ 混合矩阵, S 是 $N_k \times N$ 独立的源信号, Γ 是服从高斯分布的噪声信号,即 $\Gamma \sim N(0, \Sigma)$, 且假设 Σ 是等方性误差, $\Sigma = \sigma^2 I$ 。

根据假设条件,可以得到在参数 A 和 Σ 以及独立源 S 下观测信号的似然值:

$$p(X|A, \Sigma, S) = (\det 2\pi\Sigma)^{-\frac{N}{2}} \exp(-\frac{1}{2} \text{Tr}(X - AS)^T \Sigma^{-1} (X - AS)) \quad (2)$$

利用贝叶斯公式,则有:

$$p(S|X, A, \Sigma) = \frac{p(X|S, A, \Sigma)}{p(X|A, \Sigma)} \quad (3)$$

有噪声 ICA 模型的目的是从观测混合数据 X 中恢复未知量:独立源信号 S 、混合矩阵 A 和噪声协方差 Σ 。在这些参数估计中,独立源信号 S 的估计是主要的难点,而起源于统计物理学中的平均场近似,已被用来解决模型参数的状态估计问题,其实质是寻找一个与目标分布最接近的因子分布,这种接近程度用 KL 发散度来测量^[3,5]。下面给出利用平均场近似原理来求解 ICA 模型参数的估计算法。

2 利用平均场近似求解独立成分分析模型参数

2.1 混合矩阵 A 和噪声方差 Σ 的估计

根据公式(3),即在参数 A 和 Σ 条件下,观测混合数据 X 的似然为

$$p(X|A, \Sigma) = \int p(X|A, \Sigma, S) p(S) dS \quad (4)$$

通过 ML 对混合矩阵 A 和噪声协方差 Σ 进行估计,得到

$$A_{ML} = \arg \max_A p(X|A, \Sigma) \quad (5)$$

$$\Sigma_{ML} = \arg \max_{\Sigma} p(X|A, \Sigma) \quad (6)$$

根据公式(5)和(6),利用似然公式(4)可以得到其 log 似然函数,分别对混合矩阵 A 和协方差 Σ 求偏导数,则有

$$\frac{\partial}{\partial A} \log p(X|A, \Sigma) = \langle \frac{\partial}{\partial A} \log p(X|S, A, \Sigma) \rangle_{p(S|X, A, \Sigma)} \quad (7)$$

$\langle \cdot \rangle = \langle \cdot \rangle_{p(S|X, A, \Sigma)}$ 定义为在给定混合矩阵 A 和噪声协

方差 Σ 下,关于源信号 S 的后验均值。

同理可以得到关于噪声协方差 Σ 的偏导数

$$\frac{\partial}{\partial \Sigma} \log p(X|A, \Sigma) = \langle \frac{\partial}{\partial \Sigma} \log p(X|S, A, \Sigma) \rangle_{p(S|X, A, \Sigma)} \quad (8)$$

由公式(7)、(8)和公式(2)可以得到

$$\frac{\partial}{\partial A} \log p(X|A, \Sigma) = 0 \Rightarrow A = X \langle S \rangle^T \langle SS^T \rangle^{-1} \quad (9)$$

$$\frac{\partial}{\partial \Sigma} \log p(X|A, \Sigma) = 0 \Rightarrow \Sigma = \frac{1}{N} \langle (X - AS)(X - AS)^T \rangle \quad (10)$$

由 $\Sigma = \sigma^2 I$ 可以得到 $\sigma^2 = \frac{1}{N_m} \text{Tr} \Sigma$ 。

2.2 对增加限制条件的混合矩阵 A 的估计

我们知道,对于自然界的图像信号,由于各个特征并不同时都处于活动状态,即其特征具有稀疏性^[7],为了使提取出的特征是独立的,或尽可能独立的,本文通过限制混合矩阵 A 为非负,从而获得相对独立的特征信息,从而更有利于提高识别率。为了能限制混合矩阵 A ,通过最大后验来对混合矩阵 A 进行估计,则有

$$A_{MAP} = \arg \max_A p(A|X, \Sigma) \quad (11)$$

其中: $p(A|X, \Sigma) \propto p(X|A, \Sigma)p(A)$

根据 $p(A) = \prod_i p(A_i)$, 因此对于 A_i 如果考虑两种分布情况:零均值的高斯分布 $p(A_i) \propto \exp(-\alpha A_i^2/2)$ 和拉普拉斯分布 $p(A_i) \propto \exp(-\beta |A_i|)$, 利用非负拉格朗日乘数 $L_i > 0$ 和最大化代价函数 $\log p(A|X, \Sigma) + \text{Tr} L^T A$, 得到

$$L = \Sigma^{-1} (A \langle SS^T \rangle - X \langle S \rangle^T) + \alpha A + \beta \quad (12)$$

利用 Kuhn-Tucker 条件 $L_i A_i = 0$ ^[6] 和公式(12), 得到 $A_i > 0$ 的更新迭代计算式为

$$A_i^{(k+1)} = \frac{[\Sigma^{-1} X \langle S \rangle^T]_i}{[\Sigma^{-1} A^{(k)} \langle SS^T \rangle]_i + \alpha A_i^{(k)} + \beta} \cdot A_i^{(k)} \quad (13)$$

在实际中,对混合矩阵 A 并无先验知识,即有 $\alpha = 0, \beta = 0$, 因此根据(13)可以得到本文程序中的混合矩阵 A 的迭代公式

$$A_i^{(k+1)} = \frac{[X \langle S \rangle^T]_i}{[A^{(k)} \langle SS^T \rangle]_i} \cdot A_i^{(k)} \quad (14)$$

2.3 基于平均场近似方法的独立源信号 S 的估计

从公式(14)看出混合矩阵 A 能用 $\langle S \rangle, \langle SS^T \rangle$ 表示,因此可根据平均场近似(MFA)原理,用 $Q(S) = \prod_i Q(S_i)$ 来近似独立源信号 S 的后验分布 $p(S|X, A, \Sigma)$, 对于高斯似然值 $p(X|A, S, \Sigma), Q(S_i)$ 的最佳选择为高斯先验分布^[6],

$$Q(S_i) \propto p(S_i) \exp(-\frac{1}{2} \lambda_i S_i^2 + \gamma_i S_i) \quad (15)$$

为了简化,记

$$p(X|A, S, \Sigma) = p(X|J, h, S) = \frac{1}{C} \exp(-\frac{1}{2} \text{Tr}(S^T JS) + \text{Tr}(h^T S)) \quad (16)$$

其中 $\log C = \frac{N}{2} \log \det 2\pi \Sigma + \frac{1}{2} \text{Tr} X^T \Sigma^{-1} X$, $J = A^T \Sigma^{-1} A$, $h = A^T \Sigma^{-1} X$

利用 KL 发散度来衡量 $Q(S)$ 和 $p(S|X, A, \Sigma)$ 之间的相似度, 则有

$$\begin{aligned} KL &= \int Q(S) \log \left(\frac{Q(S)}{p(S|X, A, \Sigma)} \right) dS \propto \\ &\sum \log \int p(S_i) \exp \left(-\frac{1}{2} \lambda_i S_i^2 + \gamma_i S_i \right) dS_i + \\ &\frac{1}{2} \sum (\lambda_i - J_i) \langle S_i^2 \rangle + \\ &\text{Tr}(h - \gamma)^T \langle S \rangle + \frac{1}{2} \text{Tr} \langle S^T \rangle (\text{diag}(J) - J) \langle S \rangle - \ln C \end{aligned} \quad (17)$$

从 KL 的性质知道, $KL \geq 0$ 当且仅当 $p(S|X, A, \Sigma) = Q(S)$ 时, 等号成立。

因此合适的选取 $Q(S)$ 中的参数, 使得 KL 发散度为最小, 则有

$$\frac{\partial KL}{\partial \langle S \rangle} = 0 \Rightarrow \gamma = h - (J - \text{diag}(J)) \langle S \rangle \quad (18)$$

$$\frac{\partial KL}{\partial \langle S_i^2 \rangle} = 0 \Rightarrow \lambda_i = J_{ii} \quad (19)$$

$$\frac{\partial KL}{\partial \gamma_i} = 0 \Rightarrow$$

$$\langle S_i \rangle = \frac{\partial}{\partial \gamma_i} \log \int p(S_i) \exp \left(-\frac{1}{2} \lambda_i S_i^2 + \gamma_i S_i \right) dS_i \equiv f(\gamma_i, \lambda_i) \quad (20)$$

源信号的协方差为

$$\chi_{ij} \equiv \langle S_i S_j \rangle - \langle S_i \rangle \langle S_j \rangle \quad (21)$$

得到方差

$$\chi = [(\Lambda + J)^{-1}] \quad (22)$$

其中 $\Lambda = \text{diag}(\Lambda_1, \Lambda_2, \dots, \Lambda_{N_k})$

$$\Lambda_i = \left[\frac{\partial f(\gamma_i, \lambda_i)}{\partial \gamma_i} \right]^{-1} - J_{ii}$$

从式(20)可以看出, 均值 $f(\gamma_i, \lambda_i)$ 的计算依赖于源信号 S 的先验分布。

我们知道自然界中图像的源信号大多数情况下是为非负的, 为了限制源信号为非负, 本文利用下面的先验分布来进行图像特征的提取

$$p(S) = \eta e^{-\eta S}, \quad S \in R_+, \quad \eta > 0$$

根据高斯核和公式(20), 可以得到:

$$\begin{cases} f = \frac{1}{\sqrt{\lambda}} \frac{\zeta \Phi(\zeta) + D(\zeta)}{\Phi(\zeta)}, \\ \frac{\partial f}{\partial \gamma} = \frac{1}{\lambda} + \frac{D(\zeta)}{\sqrt{\lambda} \Phi(\zeta)} f, \end{cases} \quad \zeta = \frac{\gamma - \eta}{\sqrt{\lambda}} \quad (23)$$

3 实验结果分析

本文通过仿真模拟的图形以及 ORL 人脸数据库进行实验, 将提出的限制方法、无限制方法和传统 ICA 算法进行分析比较。

3.1 特征提取实验

仿真模拟的人脸图形数据如图 1(a) 所示, 认为该图像是混合信号 X , 将每幅大小为 50×60 的图像按列形成一个 $N = 3000$ 大小的矢量, 因此 X 为 6×3000 的矩阵。分别利用 PCA、

传统的 ICA 算法以及无限制 MFAICA 算法和限制 MFAICA 算法来获得图像的特征, 将此特征作为独立的源信号 S , 其结果如图 1 所示。从图中可以看出 PCA, 求得的源信号(特征)不容易识别, 混合了眉毛和嘴巴, 也就是说, 眉毛和嘴巴在同一成分中出现; 而用传统的 ICA 和无限制的 MFAICA 算法则没有混合眉毛和嘴巴成分, 分离就更有意义, 但是各个成分没有完全分离; 根据限制 MFAICA 算法分离的特征, 除了在所有成分中重复人脸轮廓外, 可以得到六个明显的不同特征成分。

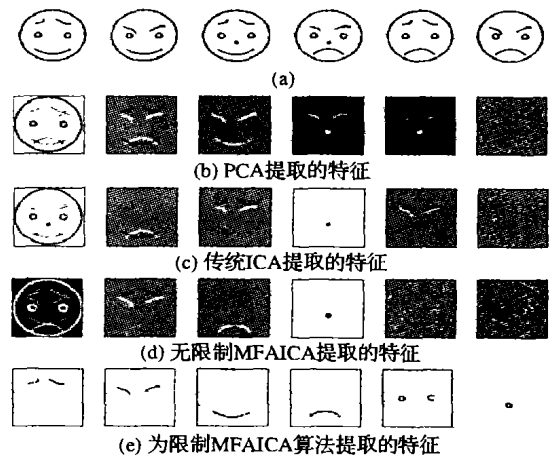


图1 仿真的图形特征提取

3.2 利用 ORL 数据库进行人脸识别实验


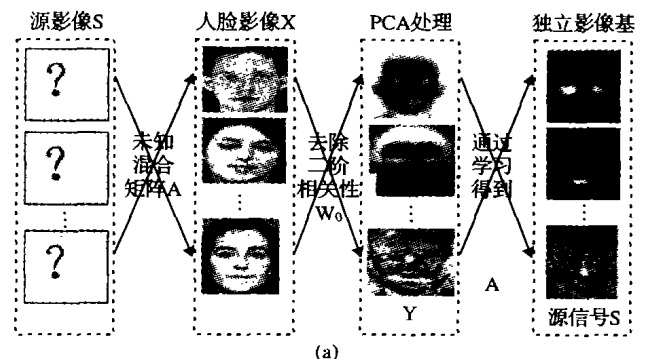


图2 ORL 人脸数据库识别结果

从网上下载剑桥大学的 ORL 人脸数据库, 该数据库中包含 40 个人, 每个人有 10 张不同表情和姿势的人脸, 存在头发等干扰。每个人抽取 5 张不同共 200 张人脸图片作为训练样本库, 其余 200 张图片为测试样本, 具体的识别过程见文献

(下转第 109 页)

下, DRshift 算法在保证 ROI 质量的同时提供了一定的背景信息, 当背景部分被全部截断时, ROI 仍得到了较好的重建。图 7 为完全提升时 DRshift 算法与最大位移法的 psnr 曲线的比较结果, 其中, 最大位移法采用上移 ROI 位平面与下移背景位平面结合的方式, 目的是为了避开上移过多造成数据溢出。

从图 7 的变化曲线中可以看出, 在低码率的情况下, DRshift 算法重建 ROI 的 psnr 值比 Maxshift 中的 psnr 值平均高 2 个 dB 左右, 在高码率情况下, 两种算法 ROI 的 psnr 值相差不大, 但整个图像包含的背景信息更多, 这是由于 DRshift 算法避免了过多位平面引入的影响, 提高了编码效率。

表 1 给出 Girl 与 Lena 图像在 8 倍压缩比下的数据比较, 评价指标为峰值信噪比 (PSNR), 单位为 dB。从结果可以看出, 在 8 倍压缩时, DRshift 算法的 ROI 的 PSNR 与最大位移法相差无几, 但由于最大位移法的下移背景系数造成部分信息的丢失, DRshift 算法的的整幅图像的 PSNR 值要高于最大位移法的图像 PSNR 值大约 0.5 个 dB。因此, 在 ROI 质量相同的情况下 DRshift 算法可提供更多的背景信息。

图 8 为只对各完全块的前 2/3 的候选截断点的失真斜率进行提升时所恢复图像的 PSNR 变化曲线, 从图中可看出, 两条曲线随码率增大渐渐重合并呈上升趋势, 说明部分 ROI 与背景一起编码, 解码时, 部分背景就随着 ROI 一起解码, 而并不是 ROI 完全恢复后, 背景才开始解码。因此, 改变失真斜率的提升因子就可实现 ROI 与背景重建图像质量的任意可调, 这一点是最大位移法做不到的。

表 1 DRshift 算法与 Maxshift 算法的实验数据比较

区域	图像	Maxshift 算法	DRshift 算法
ROI	Girl	43.33	43.34
	lena	43.57	43.60
ALL	Girl	30.21	30.73
	lena	31.62	32.15

5 结语

本文针对 Maxshift 与一般位移算法存在的不足, 根据率失真优化算法的特点, 提出了 DRshift 算法, 采用提升率失

真斜率的方法来实现 ROI 图像渐进编码, 并结合 Maxshift 法, 采取对不同的编码块进行了不同的处理的方式, 有效的实现了对任意形状 ROI 的支持。实验证明, DRshift 算法可在高压压缩比图像中实现任意感兴趣区域的高保真重建, 无需 ROI 形状信息, 计算简单, 大大提高了编码效率, 而且, 灵活控制失真斜率的提升因子可实现 ROI 与 BG 图像的任意可调, 需要说明的是, 编码效率提高的效果受 ROI 的大小的影响。而且, 由于采用的系数提升法本身的局限性, ROI 的边缘信息将略有损失, 在对 ROI 边缘信息要求比较严格的情况下, DRshift 算法将有待于进一步的完善, 这也将是下一步工作的研究重点。

参考文献:

- [1] 丁贵广, 郭宝龙. 多媒体数据压缩标准化的现状与发展[J]. 计算机工程与应用, 2002, 38(1): 104-107.
- [2] CHRISTOPOULOS C, SKODRAS A. The JPEG 2000 Still Image Coding System: An Overview[J]. IEEE Transactions on Consumer Electronics, 2000, 46(4): 1103-1127.
- [3] CHRISTOPOULOS C, ASKELOF J, LARSSON M. Efficient Methods for Encoding Regions of Interest in the Upcoming JPEG2000 Still Image Coding Standard[J]. IEEE Signal Processing letters 2000, 7(9): 247-249.
- [4] WANG Z, BOVIK AC. Bitplane-by-bitplane shift (BbBShift) - a suggestion for JPEG2000 region of interest coding[J]. IEEE Signal Processing Lett., 2000, 5(9): 160-162.
- [5] GROBOIS R, CRUZ DS, EBRAHIMI T. New approach to JPEG2000 complaint region of interest coding[A]. Proc. of the SPIE 46th Annual Meeting, Applications of Digital Image Processing XX-IV[C]. San Diego, CA, 2001.
- [6] LIU L, FAN G. A New JPEG2000 Region of Interest Image Coding method: Partial Significant Bitplanes Shift[J]. IEEE Signal Processing Letters, 2003, 10(2): 35-38.
- [7] 肖江, 邓家先, 吴成柯. 一种支持干涉多光谱图像 ROI 的压缩编码方法[J]. 光子学报, 2003, 32(4): 481-484.
- [8] TAUBMAN D. High Performance Scalable Image Compression with EBCOT[J]. IEEE Transactions on Image Processing, 2000, 9(7): 1158-1170.

(上接第 105 页)

[8], 给出识别过程如图 2(a) 所示。根据不同特征数, 分别利用传统 ICA 算法、无限制方法和限制 MFA-ICA 算法进行识别, 其识别结果如图 2(b) 所示, 从图中曲线可以看出, 本文的方法识别结果要高于传统 ICA 算法和无限制 ICA 方法。

从上面几个不同的实验结果可以看出, 限制 ICA 方法能更好的提取图像的特征, 这将更加有利于今后的识别。通过 ORL 人脸数据库进行三种算法的比较分析, 可以看出, 由于增加了限制条件, 提出的算法识别率要高于其他两种算法。

参考文献:

- [1] COMON P. Independent component analysis, a new concept?[J]. Signal Processing, 1994, 36(3): 287-314.
- [2] HYVARINEN A. Survey on independent component analysis[J]. Neural Computing Surveys, 1999, (2): 94-128.
- [3] PETERSON C, ANDERSON JR. A mean field theory learning algorithm for neural networks[J]. Complex Systems, 1987, (1): 995-1019.
- [4] ATTIAS H. Independent factor analysis[J]. Neural Computation, 1999, (11): 803-851.
- [5] TANAKA T. A theory of mean field approximation[A]. Proceedings of the 1998 conference on Advances in neural information processing systems II[C]. MIT Press. Cambridge, MA, USA, 1999. 351-357.
- [6] OPPER M, WINTHER O. Gaussian Processes for Classification: Mean Field Algorithms[J]. Neural Computation, 2000, 12(11): 2655-2684.
- [7] HYVARINEN A, KARTHIKESH R. Sparse priors on the mixing matrix in ICA [A]. Proc. Int. Workshop on ICA and BSS (ICA2000)[C]. Helsinki, Finland, 2000. 477-452.
- [8] 刘直芳, 游志胜, 等. 基于 PCA 和 ICA 的人脸识别[J]. 激光技术, 2004, 28(1): 78-81.
- [9] 刘直芳. 人脸检测和识别的研究[D]. 成都: 四川大学, 2004. 146-147.