

文章编号: 1001-3806(2005)06-0662-05

基于 RMFA-ICA 的人脸识别

刘直芳¹, 游志胜^{1*}, 张继平²

(1. 四川大学 计算机学院 图形图像研究所, 成都 610065; 2. 电子科技大学 自动化工程学院, 成都 610054)

摘要: 针对有噪声的 ICA 模型, 提出一种有限制的平均场近似 (restrictive mean field approximation, RMFA) 的算法来求解 ICA 模型参数和源信号的估计问题。在传统 MFA-ICA 算法的基础上, 提出将 ICA 中的模型参数和源信号均限制为非负, 目的是使得提取出的特征更独立, 更利于识别。通过手写体数字和仿真模拟人脸图形以及 ORL 人脸数据进行实验, 将 RMFA-ICA 算法与传统的 ICA 算法和无限制的 MFA-ICA 算法进行比较, 对于手写体数字和仿真模拟人脸图形, RMFA-ICA 算法能分离出更独立的特征, 对于 ORL 人脸数据, 其结果表明, 利用 RMFA-ICA 算法明显优于传统 ICA 算法和无限制 MFA-ICA 算法识别结果。

关键词: 平均场近似; 独立成分分析; 人脸识别; 特征提取

中图分类号: TP391.41 **文献标识码:** A

Face recognition using independent component analysis based on restricted mean field approximation

LIU Zhifang¹, YOU Zhisheng¹, Zhang Jiping²

(1. Institute of Image & Graphic, College of Computer Science, Sichuan University, Chengdu 610065, China; 2. School of Automation Engineering University Electronic Science and Technology of China, Chengdu 610054, China)

Abstract Based on mean field approximation a new method is proposed to solve noisy ICA model which can fairly well solve over-complete case and estimate the independent source by restrict the non-negative mixing matrix and the non-negative sources. The experiments have been done for several different cases, such as digital images, simulated face graphics and ORL face database. The digital images and simulated face graphics experiments show the extraction features by the RMFA-ICA are more independent than that of using tradition ICA and unrestrictive MFA-ICA, the ORL face recognition experiments show the recognition ratio by the proposed method is greater than that of using the others methods.

Key words mean field approximation; independent component analysis (ICA); face recognition; feature extraction

引 言

利用 ICA 进行盲信号分离 (blind source separation, BSS) 是近年来一个相当新且发展速度较快的领域^[1]。在大多数文献中, 主要针对无噪声独立成分分析 (independent component analysis, ICA) 模型进行了研究^[2], 但是现实世界中很多都是有噪声的情况, 同时由于无噪声 ICA 模型要求源信号数小于等于观测信号数, 因此, 存在不能分离出观测信号数小于源信号数 (over-complete)^[3]的情况, 所有这些都限制了无噪声 ICA 模型的应用。由于有噪声 ICA 模型本质上是一个概率统计估计问题, 但是直接利用传统的最大似然估计方法很难估计源信号的状态, 目前起源于统计物理

学的平均场近似 (mean field approximation, MFA) 已经广泛用来解决状态估计问题^[4-6]。ATTIAS^[5]提出利用平均场近似对有噪声 ICA 模型源信号的状态进行估计。在有噪声 ICA 的模型可以看出, 对于有噪声 ICA 模型参数的估计主要针对源信号的估计和混合矩阵估计以及噪声协方差的估计。ICA 模型中的混合矩阵和噪声协方差可以直接利用最大后验概率或最大似然估计得到, 而对于源信号的估计可以通过均值和相关性来描述。与传统 ICA 算法相比, 利用 MFA 对 ICA 模型参数的估计是没有限制的, 它可以估计观测信号数大于等于源信号数的情况, 也可以估计观测信号数小于源信号数的情况。

ATTIAS 提出的 ICA 状态估计主要是应用在信号处理中, 其源信号可能为负也可能为正, 然而在图像处理, 特别是人脸识别中, 其分离出的特征应非负, 因此, 本文中根据人脸识别的实际应用, 提出通过限制 ICA 中的模型参数和源信号均为非负, 使得分离出的特征更独立, 从而更有利于识别。通过手写体数字和

作者简介: 刘直芳 (1974-), 女, 讲师, 博士, 主要从事图像处理、计算机视觉、模式识别、人工智能方面和虚拟现实等研究。

* 通讯联系人。E-mail: zsyoun@mail.sc.cninfo.net

收稿日期: 2004-06-14 收到修改稿日期: 2004-10-10

仿真模拟的人脸图形以及 ORL 人脸数据进行实验, 从实验结果来看, 对于手写体和仿真模拟的人脸图形, 提出的 MFA-ICA 算法能很好地分离出独立的特征, 而对于 ORL 人脸数据, 其结果优于传统 ICA 算法和 ATTAS 的无限制条件算法的识别结果。

1 独立成分分析和平均场近似

1.1 独立成分分析

独立成分分析是解决盲信号分离 BSS 问题的一个被广泛应用的方法, 一般认为, ICA 是 PCA (principle component analysis) 的延伸^[1, 2]。现在大多数应用的 ICA 模型是无噪声 ICA 模型, 该模型对有些问题没能取得很好的分离效果, 同时, 由于实际应用中存在大量的噪声, 因此, 在此考虑有噪声 ICA 模型, 即:

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

式中, 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, $\Sigma = \varepsilon^2 I$

则通过上述假设, 可以得到在参数 A 和 Σ 以及独立源 S 下的似然值:

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

根据贝叶斯公式, 有:

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

从上述模型可以看出, 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 。如果在给定足够的源信号 S 估计下, 混合矩阵 A 和噪声协方差 Σ 的估计相对而言就简单容易, 混合矩阵 A 可以通过最大后验概率 (MAP) 进行估计, 噪声协方差 Σ 可以通过最大似然 (ML) 进行估计, 在这些参数估计中, 独立源信号 S 的估计是难点。本文中采用平均场近似的方法对独立源信号 S 的状态进行估计。

1.2 平均场近似

为了更好地描述对独立源信号 S 的估计, 给出简单的平均场近似的定义。平均场近似起源于统计物理学中, 现已经被广泛应用在实际问题中, 解决参数模型中的状态期望的估计问题。在信息处理中, 平均场近似主要应用在玻耳兹曼机等^[4, 6]。平均场近似的定义是寻找一个与目标分布最接近的因子分布, 一般情况下, 这种接近程度用 KL 发散度来测量^[4, 6]。

假设 $x = \{x_1, x_2, \dots, x_n\}$ 为 n 维矢量, $p(x | \Theta)$ 为参数 Θ 下 x 的概率分布, $\mathcal{R} = \{p(x | \Theta)\}$ 在参数 Θ 下得

到的所有概率分布的集合簇。如果假设 $\Theta = (\Theta, w)$, 定义其中的子集 $M \subset \mathcal{R}$, $w = 0$ 即在子集中满足 $q(x | \Theta) = p(x | \Theta, w = 0)$ 条件。设任意一个目标概率分布 $p(x | \Theta, w) \in \mathcal{R}$, 定义与 $p(x | \Theta, w)$ 最接近的平均场近似因子分布 $q(x | \Theta')$, 利用 KL 发散度来测度其接近程度:

$$S_{KL} = \sum_x p(x | \Theta, w) \log \frac{p(x | \Theta, w)}{q(x | \Theta')} \quad (4)$$

$$q(x | \Theta') = \prod_{i=1}^n q_i(x_i | \Theta') \quad (5)$$

通过拉格朗日定义, 寻找最佳 q 必须满足:

$$q_i(x_i | \Theta'_i) = p(x_i | \Theta, w) \quad (6)$$

上式表明, 要使 q 最接近 p , 则必须寻找一个与目标分布 p 有相同边缘分布的因子分布, 然而由于 p 是很难直接求解的, 直接从上式获得最佳接近 q 是不现实的, 因此, 根据参数变化 $\Delta\Theta = \Theta - \Theta'$, $\Delta w = w - 0$ 来寻找最佳近似 q , 定义 $\Delta\Theta = (\Delta\Theta, \Delta w)$:

$$\log p(x_i | \Theta, w) = \log q_i(x_i | \Theta'_i) + \Delta \log p(x_i) \quad (7)$$

式中, $\Delta \log p(x_i) = \sum_J \left[\frac{\partial \log p(x_i)}{\partial \Theta_J} \right]_q \Delta \Theta_J + \frac{1}{2} \times \sum_K \left[\frac{\partial^2 \log p(x_i)}{\partial \Theta_J \partial \Theta_K} \right]_q \Delta \Theta_J \Delta \Theta_K + o(\varepsilon^n)$, $o(\varepsilon^n)$ 近似为 0 略去。等式的左边是通过 (6) 式得到的, 即表示 q 与 p 最接近。等式右边是通过拉格朗日定义获得。

2 平均场近似独立成分分析模型参数估计

根据有噪声 ICA 模型的目的, 从观测混合数据中估计独立源信号 S 、混合矩阵 A 和噪声协方差 Σ 。下面分别给出混合矩阵 A 和噪声协方差 Σ 以及独立源信号 S 的估计。

2.1 混合矩阵 A 和噪声方差 Σ 估计

根据 (3) 式, 即在参数 A 和 Σ 条件下, 观测混合数据 X 的似然为:

$$p(X | A, \Sigma) = \int p(X | A, \Sigma, S) p(S) dS \quad (8)$$

ATTAS 利用 (8) 式对混合矩阵 A 和噪声协方差 Σ 通过 ML 进行估计, 有:

$$A_{ML} = \arg \max_A p(X | A, \Sigma) \quad (9)$$

$$\Sigma_{ML} = \arg \max_{\Sigma} p(X | A, \Sigma) \quad (10)$$

根据 (9) 式和 (10) 式, 对 (8) 式取 \log 对数函数, 同时根据 $\frac{\partial}{\partial x} \lg f(x) = \frac{1}{f(x)} \frac{\partial}{\partial x} f(x)$, 并分别对混合矩阵 A 和协方差 Σ 求偏导数, 则有:

$$\frac{\partial}{\partial A} \log p(X | A, \Sigma) =$$

$$\left\langle \frac{\partial}{\partial A} \log p(X | S, A, \Sigma) \right\rangle_{p(S|X, A, \Sigma)} \quad (11)$$

$\langle \cdot \rangle = \langle \cdot \rangle_{p(S|X, A, \Sigma)}$ 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 的后验平均。同理可以得到关于噪声协方差 Σ 的偏导数:

$$\frac{\partial}{\partial \Sigma} \log p(\mathbf{X} | \mathbf{A}, \Sigma) = \langle \frac{\partial}{\partial \Sigma} \log p(\mathbf{X} | \mathbf{S}, \mathbf{A}, \Sigma) \rangle_{p(\mathbf{S} | \mathbf{X}, \mathbf{A}, \Sigma)} \quad (12)$$

由 (11) 式、(12) 式和 (2) 式,可以得到 \mathbf{A} 和 Σ 的估计:

$$\frac{\partial}{\partial \mathbf{A}} \log p(\mathbf{X} | \mathbf{A}, \Sigma) = \Sigma^{-1} (\mathbf{X} \langle \mathbf{S} \rangle^T - \mathbf{A} \langle \mathbf{S} \mathbf{S}^T \rangle) = 0 \Rightarrow \mathbf{A} = \mathbf{X} \langle \mathbf{S} \rangle^T \langle \mathbf{S} \mathbf{S}^T \rangle^{-1} \quad (13)$$

$$\frac{\partial}{\partial \Sigma} \log p(\mathbf{X} | \mathbf{A}, \Sigma) = \frac{1}{2} \Sigma^{-1} \langle (\mathbf{X} - \mathbf{A} \mathbf{S}) (\mathbf{X} - \mathbf{A} \mathbf{S})^T \rangle \Sigma^{-1} - \frac{N}{2} \Sigma^{-1} \Rightarrow \Sigma = \frac{1}{N} \langle (\mathbf{X} - \mathbf{A} \mathbf{S}) (\mathbf{X} - \mathbf{A} \mathbf{S})^T \rangle \quad (14)$$

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

2.2 增加限制的混合矩阵 \mathbf{A} 的估计

在自然界的图像中,由于其图像特征具有稀疏性^[7],即每个特征并不同时处于活动状态,因此,为了更好的提取图像中的特征,限制混合矩阵 \mathbf{A} 为非负,然后利用最大后验 (MAP) 对 \mathbf{A} 进行估计,即:

$$\mathbf{A}_{\text{MAP}} = \arg \max_{\mathbf{A}} p(\mathbf{A} | \mathbf{X}, \Sigma), \quad p(\mathbf{A} | \mathbf{X}, \Sigma) \propto p(\mathbf{X} | \mathbf{A}, \Sigma) p(\mathbf{A}) \quad (15)$$

式中, $p(\mathbf{A}) = \prod_i p(A_i)$ 。

对于 A_i 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 $\lambda_i > 0$ 和更改的最大化代价函数 $\log p(\mathbf{A} | \mathbf{X}, \Sigma) + \text{Tr} \mathbf{L}^T \mathbf{A}$, 得到:

$$\mathbf{L} = \Sigma^{-1} (\mathbf{A} \langle \mathbf{S} \mathbf{S}^T \rangle - \mathbf{X} \langle \mathbf{S} \rangle^T) + \alpha \mathbf{A} + \beta \quad (16)$$

利用 Kuhn-Tucker 条件 $L A_i = 0$ ^[6] 和 (16) 式,得到 $A_i > 0$ 的迭代计算式为:

$$A_i^{(k+1)} = \frac{[\Sigma^{-1} \mathbf{X} \langle \mathbf{S} \rangle^T]_i}{[\Sigma^{-1} \mathbf{A}^{(k)} \langle \mathbf{S} \mathbf{S}^T \rangle]_i + \alpha A_i^{(k)} + \beta} A_i^{(k)} \quad (17)$$

一般情况下,对于混合矩阵 \mathbf{A} 无先验知识,即有 $\alpha = 0$ $\beta = 0$ 此时得到混合矩阵 \mathbf{A} 迭代公式为:

$$A_i^{(k+1)} = \frac{[\mathbf{X} \langle \mathbf{S} \rangle^T]_i}{[\mathbf{A}^{(k)} \langle \mathbf{S} \mathbf{S}^T \rangle]_i} A_i^{(k)} \quad (18)$$

2.3 独立源信号 S 的估计

从 (18) 式看出,混合矩阵 \mathbf{A} 和噪声协方差 Σ 能用 $\langle \mathbf{S} \rangle$, $\langle \mathbf{S} \mathbf{S}^T \rangle$ 表示。根据平均场近似 MFA 原理,用可分解分布 $Q(\mathbf{S}) = \prod_i Q(S_i)$ 近似独立源信号 S 的后验分布 $p(\mathbf{S} | \mathbf{X}, \mathbf{A}, \Sigma)$ 。对于高斯似然值 $p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma)$, ATTIAS^[5] 提出, $Q(S_i)$ 的最佳选择为高斯先验分布,即:

$$Q(S_i) \propto p(S_i) \exp\left[-\frac{1}{2} \lambda_i S_i^2 + \gamma_i S_i\right] \quad (19)$$

简记 $p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma) = p(\mathbf{X} | \mathbf{J}, \mathbf{h}, \mathbf{S}) = \frac{1}{C} \exp[-\frac{1}{2} \times \text{Tr}(\mathbf{S}^T \mathbf{J} \mathbf{S}) + \text{Tr}(\mathbf{h}^T \mathbf{S})]$, 式中, $\log C = \frac{N}{2} \lg \det 2\pi \Sigma + \frac{1}{2} \times \text{Tr} \mathbf{X}^T \Sigma^{-1} \mathbf{X}$, 而: $\mathbf{J} = \mathbf{A}^T \Sigma^{-1} \mathbf{A}$, $\mathbf{h} = \mathbf{A}^T \Sigma^{-1} \mathbf{X}$ (20) 根据 (4) 式、(7) 式衡量 $Q(\mathbf{S})$ 和 $p(\mathbf{S} | \mathbf{X}, \mathbf{A}, \Sigma)$ 之间的相似度:

$$S_{\text{KL}} = \int Q(\mathbf{S}) \log \left[\frac{Q(\mathbf{S})}{p(\mathbf{S} | \mathbf{X}, \mathbf{A}, \Sigma)} \right] d\mathbf{S} \propto \sum_i \log \int p(S_i) \times \exp\left[-\frac{1}{2} \lambda_i S_i^2 + \gamma_i S_i\right] dS_i + \frac{1}{2} \sum_i (\lambda_i - J_{ii}) \langle S_i^2 \rangle + \text{Tr}(\mathbf{h} - \gamma)^T \langle \mathbf{S} \rangle + \frac{1}{2} \text{Tr} \langle \mathbf{S}^T \rangle [\text{diag}(\mathbf{J}) - \mathbf{J}] \langle \mathbf{S} \rangle - \ln C \quad (21)$$

从 S_{KL} 的性质可知, $S_{\text{KL}} \geq 0$ 且仅当 $p(\mathbf{S} | \mathbf{X}, \mathbf{A}, \Sigma) = Q(\mathbf{S})$, 等号成立。

因此,选取 $Q(\mathbf{S})$ 中的参数,使得 S_{KL} 发散度为最小,用参数分别对 S_{KL} 求偏导,得到:

$$\frac{\partial S_{\text{KL}}}{\partial \langle \mathbf{S} \rangle} = 0 \Rightarrow \gamma = \mathbf{h} - [\mathbf{J} - \text{diag}(\mathbf{J})] \langle \mathbf{S} \rangle \quad (22)$$

$$\frac{\partial S_{\text{KL}}}{\partial \langle S_i \rangle} = 0 \Rightarrow \lambda_i = J_{ii} \quad (23)$$

$$\frac{\partial S_{\text{KL}}}{\partial \gamma_i} = 0 \Rightarrow \langle S_i \rangle = \frac{\partial}{\partial \gamma_i} \log \int p(S_i) \times \exp\left[-\frac{1}{2} \lambda_i S_i^2 + \gamma_i S_i\right] dS_i = f(\gamma_i, \lambda_i) \quad (24)$$

源信号的协方差为: $x_{ij} = \langle S_i S_j \rangle - \langle S_i \rangle \langle S_j \rangle$ 。

可得协方差矩阵:

$$\mathbf{x} = [\mathbf{\Lambda} + \mathbf{J}]^{-1} \quad (25)$$

式中, $\mathbf{\Lambda} = \text{diag}(\Lambda_1, \Lambda_2, \dots, \Lambda_N)$, $\Lambda_i = \left[\frac{\partial f(\gamma_i, \lambda_i)}{\partial \gamma_i} \right]^{-1} - J_{ii}$ 。

2.4 增加限制条件的源信号 S 先验分布

从 (24) 式可以看出,均值 $f(\gamma_i, \lambda_i)$ 的计算依赖于源信号 S 的先验分布。在 ICA 中常用的几种源信号先验分布为混合高斯分布、拉普拉斯分布^[2] 等。对于拉普拉斯先验分布主要用于语音信号等处理分析,而 ATTIAS 利用混合高斯先验分布进行图像特征的提取,但是为了使得提取的特征更具有独立性,有利于后期的识别处理,本文中通过限制源信号 S 为非负的指数先验分布来进行特征提取。这是因为指数分布与混合高斯分布都是一种次高斯类型的函数^[2],从这一点也说明,对于 MFA-ICA 算法,并不需要准确知道源信号的分布,而只需知道是哪种类型的分布即可。

设限制的先验指数分布为:

$$p(S) = \eta e^{-\eta S}, S \in R_+, \eta > 0 \quad (26)$$

利用公式 $D(x) = \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{1}{2} x^2\right]$, $D'(x) = -xD(x)$

和 $\Phi(x) = \int_{-\infty}^x D(t)dt, \Phi'(x) = D(x)$ 。得到:

$$\begin{cases} f = \frac{1}{\sqrt{\lambda}} \frac{\xi\Phi(\xi) + D(\xi)}{\Phi(\xi)} \\ \frac{\partial f}{\partial y} = \frac{1}{\lambda} + \frac{D(\xi)}{\sqrt{\lambda}\Phi(\xi)} f \end{cases}, \xi = \frac{y-\eta}{\sqrt{\lambda}} \quad (27)$$

具体的推导过程见文献 [9]。

2.5 MFA-ICA 算法的估计步骤

为了更好地说明和描述 MFA-ICA 算法,下面给出利用 EM 迭代算法计算 MFA-ICA 的步骤。

(1)初始化过程。根据 (20)式和 (23)式对所需要的初始化参数进行计算, 即有: $J = A^T \Sigma^{-1} A, h = A^T \Sigma^{-1} X, \langle S \rangle = 0, \lambda_i = J_{ii}$ 。

(2)求期望过程 (E 步)。对于求期望, 首先根据 (22)式和 (24)式, 求出: $y = h - [J - \text{diag}(J)] \langle S \rangle, \delta \langle S \rangle = f(y, \lambda) - \langle S \rangle, \langle S \rangle = \langle S \rangle + \eta \delta \langle S \rangle$ 。

然后根据 (25)式计算得到: $\Lambda_i = \left[\frac{\partial f(y_i, \lambda_i)}{\partial \lambda_i} \right]^{-1} - \lambda_i$,

$$\delta \lambda_i = \frac{1}{[\Lambda + J]^{-1} J_{ii}} - \frac{1}{\left[\frac{\partial f(y_i, \lambda_i)}{\partial \lambda_i} \right]}, \lambda_i = \lambda_i + \delta \lambda_i$$

$$x = (\Lambda + J)^{-1}$$

(3)最大化过程 (M 步)。根据 (18)式, 有: $\delta A_i = \frac{[X \langle S \rangle^T]_i}{[A^{(k)} \langle SS^T \rangle]_i} A_i - A_i, A_i = A_i + \delta A_i$ 。

根据 (14)式, 有: $\delta \Sigma = \frac{1}{M} \langle (X - AS)(X - AS)^T \rangle - \Sigma, \Sigma = \Sigma + \delta \Sigma$ 。

(4)停止准则。迭代计算第 2 步和第 3 步, 直到满足停止条件为止, 停止条件为: $\max(|\delta \langle S \rangle|^2, |\delta \lambda_i|^2, |\delta A_i|^2, |\delta \Sigma_i|^2) < 10^{-5}$ 。

如果不满足, 则将上面计算得到的值代入下式计算: $J = A^T \Sigma^{-1} A, h = A^T \Sigma^{-1} X$ 。

重复第 2 步和第 3 步, 直到满足停止条件为止。

3 实验结果

通过手写体数字、仿真模拟的人脸图形以及 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 算法进行比较, 可以看出, 提出的限制方法能更好地提出图像的特征, 这将更加有利于今后的识别, 通过 ORL 人脸数据库进行 3 种算法的比较分析, 由于增加了限制条件, 提出的算法识别率要高于其它两种算法。

3.1 手写体数字和仿真模拟人脸图形特征提取
为了说明本文中的方法的特点, 利用文献 [5] 中的手写体数字库 (见图 1a) 和仿真人脸图形 (见图 2a) 进行实验。利用 MNIST 数字影像库提供的手写体数字影像, 取 500 个手写体数字“3”, 假设有 25 个隐含影像。图 1b 为传统 ICA 算法提取的特征, 图 1c 为文




Fig 1 The features of script digital images




Fig 2 The features of simulation face graphics

a— original image b— the extraction features by PCA c— the extraction features by traditional ICA d— the extraction features by references [5] e— the extraction features by the proposed method

献 [5] 中无限制 MFA-ICA 方法提取的特征, 图 1d 为本文中的 RMFA-ICA 方法提取的特征。从图中可以看出, 传统 ICA 算法和文献 [5] 中算法提取的特征不具有独立性, 在每个成分中混合了其它特征, 而本文中的

方法提取的特征似乎是手写体“3”的笔画顺序, 在每个成分中只有一个特征处于活动状态, 即这些特征更具有独立性, 这将更有利于后期的识别处理。

对于仿真模拟的人脸图形数据 (见图 2a), 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 MFA-ICA 算法和 RMFA-ICA 算法来获得图像的特征, 将此特征作为独立的源影像 S , 其结果如图 2 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 MFA-ICA 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 RMFA-ICA 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 6

个明显的不同特征成分。

3.2 ORL 人脸数据库

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, 具体的识别过程参见文献 [8] 和文献 [9]。简要识别过程如图 3a 所示。根据不同特征数, 分别利用传统 ICA 算法、无限制 MFA-ICA 方法和 RMFA-ICA 算法进行识别, 其识别结果见图 3b。

从图中曲线可以看出, 当选用 10 到 30 个特征数




Fig 3 The ORL face recognition

a—the recognition process b—the recognition results by the different methods

时, 几种识别方法的差别不是很明显, 但是当选用大于 40 个特征数进行识别时, 文中方法的识别率明显要高于传统 ICA 算法和无限制条件 ICA 算法。因此, 该方法识别结果要高于传统 ICA 算法和无限制 ICA 方法。

4 结论

从上面几个不同的实验结果可以看出, 限制 ICA 方法相比传统 ICA 和 PCA 算法能提取出更独立的特征, 这将更加有利于今后的识别。通过 ORL 人脸数据库进行 3 种算法的比较分析, 由于增加了限制条件, 提出的算法识别率要高于其它两种算法。

参考文献

[1] COMON P. Independent component analysis: a new concept [J]. Signal Processing, 1994, 36(3): 287~314

[2] HYVARNEN A. Survey on independent component analysis [J]. Neural Computing Surveys, 1999, 1(2): 94~128

[3] LEWICKIM S. Learning over complete representations [J]. Neural Computation, 2000, 12(2): 337~365

[4] PETERSON A. A mean field theory learning algorithm for neural networks [J]. Complex Systems, 1987, 24(1): 995~1019.

[5] ATTIAS H. Independent factor analysis [J]. Neural Computation, 1999, 11(4): 803~851.

[6] TANAKA T. A theory of mean field approximation [A]. Advances in Neural Information Processing Systems [C]. Massachusetts MIT Press, 1999, 351~357.

[7] HYVARNEN A, KARTH KESH R. Sparse priors on the mixing matrix in ICA [A]. Proc Int Workshop on ICA and BSS (ICA2000) [C]. Helsinki Helsinki University Press, 2000, 477~452.

[8] 刘直芳, 游志胜, 王运琼. 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.