

Tied Factor Analysis for Face Recognition across Large Pose Differences

Simon Prince, James Elder, Jonathan Warrell, and Fatima Felisberti

讲解人: 李安南

中科院计算所JDL人脸组Seminar

2009年3月19日

第二作者

James H. Elder

Associate Professor

Department of Computer Science and Engineering

Department of Psychology

York University, Canada

<http://elderlab.yorku.ca/~elder/>



学术背景:

- ▶ 1995年在麦基尔(McGill)大学获得电子工程博士学位。1995到1996年在位于普林斯顿的NEC研究院工作。
- ▶ 1996到2006年在加拿大约克大学心理学系任教。2006开始在计算机和心里学两个系任教。
- ▶ 是第一作者在加拿大期间的博士后导师。

第三作者

Jonathan Warrell

Research Associate

Department of Computer Science

University College of London

<http://www.cs.ucl.ac.uk/people/J.Warrell>



学术背景:

- ▶ 在剑桥大学获得**音乐**学士
- ▶ 在伦敦大学学院获得计算机硕士
- ▶ 在伦敦大学国王学院(King's College London)获**音乐理论和分析**博士学位

一些题外话

后续胶片中包含UCL字样的取自作者在BMVC2006上的幻灯片

<http://www.cs.ucl.ac.uk/staff/s.prince/Papers/BMVCPresentation2006.pdf>

摘要翻译

- ▶ 当注册图像和测试图像的姿态不一致的时候，人脸识别算法变得不可靠，这是因为对于典型的特征向量由于姿态导致的变化大于由身份不同带来的变化。
- ▶ 我们提出一种可以将理想中的“身份”空间一对多的映射到观察到数据空间的产生式模型。在“身份”空间中个体并不随姿态变化而变化。
- ▶ 在高斯噪声条件下，特征向量可以认为是由“身份”变量映通过“姿态可选”的线性变换投影所得到的。我们称这一模型为“联结的”因子分析。
- ▶ 线性变换(因子)的选择依赖于姿态，但对于某个特定的人所载荷(loadings)的(身份信息)是不变的(联结的)。
- ▶ 我们使用期望最大化(EM)算法从训练数据中估计线性变换和噪声的参数。
- ▶ 我们提出一种允许获取可能的匹配的完整的后验的概率距离度量。
- ▶ 我们引入了一种新的特征提取过程并使用FERET, XM2VTS和PIE数据库验证识别性能。识别性能和目前的方法相比显得很"好"。

这篇文章的要点

- ▶ "联结的"因子分析模型与人脸识别中的姿态问题
- ▶ EM算法和本文中模型参数的求解(这部分放在后面讲)
- ▶ 基于概率距离度量的识别
- ▶ 实验结果分析



因子分析简介

因子分析的一般形式, p 维空间中的向量 x 可表示为:

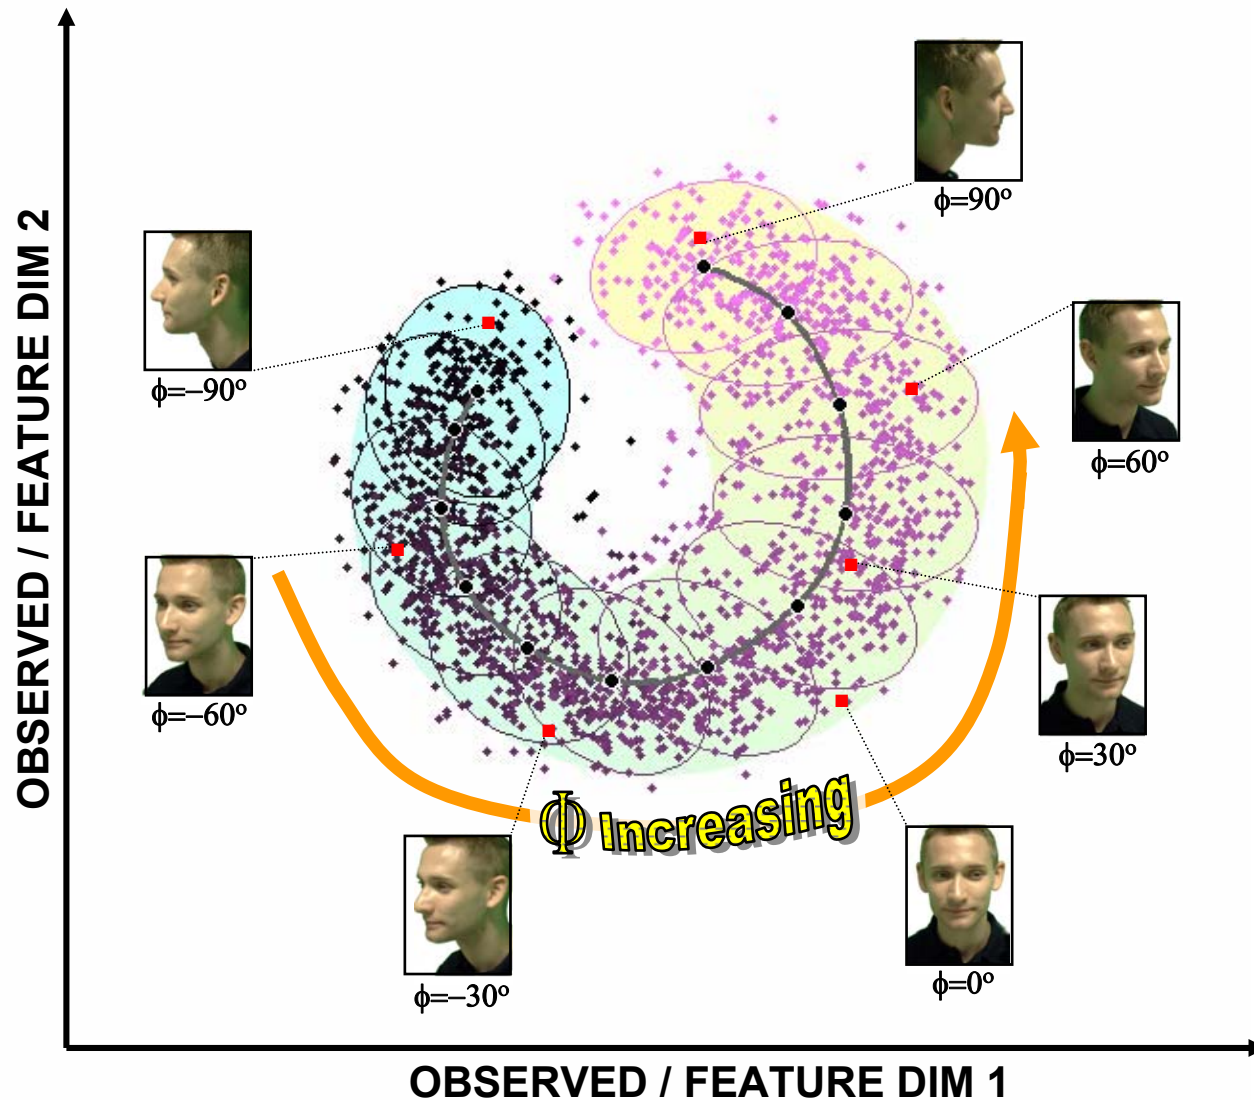
$$x_{p \times 1} = A_{p \times m} F_{m \times 1} + \epsilon_{p \times 1} \quad (1)$$

A 称为载荷矩阵, F 则称作公共因子, ϵ 称作特殊因子, m 为因子个数

因子分析和主成分分析之间的关系

- ▶ 这里先不妨把他看做PCA(因子分析和PCA本质上有很多共通之处)
- ▶ 本质上和PCA一样, 都是在降维。
- ▶ 与PCA的不同, 因子分析中的因子数(维数)是事先确定的。
- ▶ 因子分析还多一道工序: 因子旋转(本文中未涉及)。


Data with Pose Differences



不同姿态人脸图像的特征

不同姿态的人脸图像可以表示为:

$$x_{ijk} = F_k h_i + m_k + \epsilon_{ijk} \quad (2)$$



- ▶ 其中 i 表示身份, k 表示姿态, j 表示样本。
- ▶ h 称为隐含身份变量, m 表示均值, F 是投影矩阵。
- ▶ 这里 ϵ_{ijk} 是 0 均值的高斯噪声项, 一个未知的对角协方差矩阵 Σ_k 。
- ▶ 本文假定对每个人 h 是不变的, 所以因子"联结"了(tied)。

不同姿态人脸图像的特征(续)

- ▶ 用条件概率将公式(2)形式化

$$Pr(x_{ijk}|h_i) = \mathcal{G}_x[F_k h_i + m_k, \Sigma_k] \quad (3)$$

$$Pr(h_i) = \mathcal{G}_h[0, I] \quad (4)$$

- ▶ 其中 $\mathcal{G}_a[b, C]$ 表示对于变量 a 的一个均值为 b 协方差为 C 的高斯分布。
- ▶ 参数 $\theta = \{F_1 \dots F_K, m_1 \dots m_K, \Sigma_1 \dots \Sigma_K\}$ 可以通过EM算法求解。

基于概率距离度量的识别

- ▶ 我们已经通过EM算法得到了

$$\theta = \{F_1 \dots F_K, m_1 \dots m_K, \Sigma_1 \dots \Sigma_K\}$$

- ▶ 利用这些参数将一个姿态的图像变换到另一个姿态下是一种很自然的做法。但由于方差项的问题，这样的方法存在不确定性。





- ▶ 在 Σ 允许的范围从一幅正面人脸图像预测的非正面图像可以是多种多样的。

基于概率距离度量的识别(续)

- ▶ 另一种自然的思路是去比较两幅图像对应的 h 的相似度(这也是PCA等方法常见的做法)。
- ▶ 由于方差项, 推导上这样的方法也有问题。作者选择了回避直接比较 h 的做法。
- ▶ 具体的识别方法是, 假设Gallery中有 N 个人, 则输入图像就有 N 种匹配的可能(见下一页图示)。
- ▶ 通过比较这 n 种模型的后验概率来确定输入图像最终和Gallery中哪个人匹配。

Recognition – compare likelihoods of models



基于概率距离度量的识别(续)

- ▶ 对于每一种可能的匹配模型 \mathcal{M}_n ，将输入图像和Gallery图像串联成一个长的向量。考察这个向量的分布，给出(属于同一人的)概率。

$$\begin{bmatrix} x_1 \\ \vdots \\ x_Q \end{bmatrix} = \begin{bmatrix} F_1 \\ \vdots \\ F_Q \end{bmatrix} h_i + \begin{bmatrix} m_1 \\ \vdots \\ m_Q \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \vdots \\ \epsilon_Q \end{bmatrix}$$

或者 $x' = F' h_i + m' + \epsilon'$

- ▶ 这是一个标准的因子分析的形式，其似然符合 $\mathcal{G}_{x'}[m', F'F^T + \Sigma']$. 其中 $\Sigma' = \text{diag}[\Sigma_1, \Sigma_2 \dots \Sigma_P]$

基于概率距离度量的识别(续)

- ▶ 最后依据贝叶斯法则计算最终的概率:


$$Pr(\mathcal{M}_n|x_{1...N}, x_p, \theta) = \frac{Pr(x_{1...N}, x_p|\mathcal{M}_n, \theta)Pr(\mathcal{M}_n)}{\sum_{m=1}^N Pr(x_{1...N}, x_p|\mathcal{M}_m, \theta)Pr(\mathcal{M}_m)} \quad (5)$$

- ▶ 其中 $Pr(\mathcal{M}_n)$ 为每个模型的先验概率，文章中设其为 $\frac{1}{N}$
- ▶ 最终的分类结果选择具有最大后验的模型。

实验结果分析





在普通灰度特征上的实验

可以看出本文方法能够取得明显的效果，但性能水平一般。



实验结果分析(续)

利用特征点+局部Gabor特征的情况下
本文的方法和目前已知的最好结果
(例如3DMM)相当。



用EM算法估计参数

- ▶ 需要估计的参数 $\theta = \{F_1 \dots F_K, m_1 \dots m_K, \Sigma_1 \dots \Sigma_K\}$ 。
- ▶ 除了 θ 外, h 也是隐含的未知的。这样的 "chicken-and-egg" 问题可用EM算法求解。
- ▶ 通过更新参数 θ 最大化 $Pr(x, h|\theta)$ 的联合似然度(joint likelihood):

$$Q(\theta_t, \theta_{t-1}) = \sum_{i=1}^I \int Pr(h_i | x_{i..}, \theta_{t-1}) \left[\sum_{j=1}^J \sum_{k=1}^K \log Pr(x_{ijk} | h_i, \theta_t) + \log Pr(h_i) \right] dh_i \quad (6)$$

- ▶ 注意: 这里隐含变量是一个**分布**, 也就是说 h 的期望包含一个均值向量 $E(h)$ 和一个协方差矩阵 $E(hh^T)$ 。

用EM算法估计参数(续)

E-步: 计算 h 的分布的期望

$$E[h_i|x_{i..}] = (I + \sum_{j=1}^J \sum_{k=1}^K F_k^T \Sigma_k^{-1} F_k)^{-1} \cdot \sum_{j=1}^J \sum_{k=1}^K F_k^T \Sigma_k^{-1} (x_{ijk} - m_k) \quad (7)$$

$$E[h_i h_i^T | x_{i..}] = (I + \sum_{j=1}^J \sum_{k=1}^K F_k^T \Sigma_k^{-1} F_k)^{-1} + E[h_i | x_{i..}] E[h_i | x_{i..}]^T \quad (8)$$

用EM算法估计参数(续)

M-步: 估计参数 θ , 令 $\tilde{F}_k = [F_k, m_k], \tilde{h}_i = [h_i^T, 1]^T$. 更新规则变为:

$$\tilde{F}_k = \left(\sum_{i=1}^I \sum_{j=1}^J x_{ijk} E[\tilde{h}_i | x_{i..}]^T \right) \cdot \left(\sum_{i=1}^I \sum_{j=1}^J E[\tilde{h}_i \tilde{h}_i^T | x_{i..}] \right)^{-1} \quad (9)$$

$$\Sigma_k = \frac{1}{IJ} \sum_{i=1}^I \sum_{j=1}^J \text{diag}[x_{ijk} x_{ijk}^T - \tilde{F}_k E[\tilde{h}_i | x_{i..}] x_{ijk}^T] \quad (10)$$

谢谢!

