

基于子空间投影的残缺人脸图像识别新算法

蒲晓蓉, 郑自明, 周伟

(电子科技大学计算机科学与工程学院 成都 610054)

【摘要】提出了改进的基于子空间投影的残缺人脸图像识别新算法,利用非负稀疏矩阵将原始人脸图像分解,从高维空间降低到低维子空间,再利用Fisher线性判别式方法进一步降低子空间维数;然后利用欧式距离测量法,识别待测试人脸。实验证明,对残缺人脸图像的识别,新算法具有满意的识别率。

关键词 Fisher线性判别式; 子空间; 人脸识别; 主成分分析

中图分类号 TP491.41

文献标识码 A

An Improved Subspace Method for Recognizing Imprecisely Fragmentary Faces

PU Xiao-rong, ZHENG Zi-ming, ZHOU Wei

(School of Computer Science and Engineering, UEST of China Chengdu 610054)

Abstract An improved subspace method is proposed for recognizing imprecisely fragmentary faces. This method integrates non-negative matrix factorization with sparseness constraints and Fisher's linear discriminant analysis subspace. Comparative experiments show that our novel subspace has recognition performance better than PCA subspace in recognizing imprecisely fragmentary faces.

Key words Fisher's linear discriminant; subspace; face recognition; principal component analysis

自动人脸识别,因为具有极强的科学研究挑战性和潜在的广泛应用,一直是国际性的研究热点。然而,迄今为止,绝大多数人脸识别研究都针对受限条件下的完整人脸图像,很少研究非完整的或残缺的人脸图像识别。事实上,人脸识别系统的性能与待识别的人脸图像质量紧密相关。因此,有必要研究残缺人脸图像的识别方法,以识别那些因为采集条件欠佳,或从某些序列图像中裁剪的、不完整的人脸图像。

人脸识别的第一步,需要对高维人脸空间进行降维处理,以降低计算复杂度,节省存储空间。大多数人脸识别系统将人脸表示为基图像的线性组合,基图像可以基于局部特征,也可以基于全局特征^[1]。主成分分析(Principal Component Analysis, PCA)方法基于人脸的全局特征基^[2],通过求解相关矩阵的最大特征值对应的特征向量,将人脸高维空间降低到低维特征子空间。非负稀疏矩阵分解基于人脸的局部特征^[1, 3],通过近似的矩阵分解进行空间降维。Fisher线性判别式方法能找到一个理想的空间投影方向^[4],使被投影空间中的点能很好地聚类,从而使待识别人脸更易于识别。本文提出了基于Fisher非负稀疏矩阵分解的非完整人脸识别算法。

1 基于非负稀疏矩阵分解及主成分分析的空间降维方法

在自动人脸识别系统中,可以将一张2D人脸图像看作图像空间中的一个 $i \times j$ 向量。一组人脸样本可以表示为 $n \times m$ 矩阵 $V=[V_1, V_2, \dots, V_m]$,矩阵的每一列由 $n=i \times j$ 个非负的像素值构成,该矩阵包含 m 个这样的列。另外, m 个人脸样本属于 c 类。首先介绍如何利用非负稀疏矩阵分解和主成分分析进行图像空间降维。

1.1 非负稀疏矩阵分解

非负稀疏矩阵分解方法旨在将一组人脸样本矩阵近似地分解为一个非负基图像矩阵和一个非负编码系数矩阵,即 $V \approx WH$,其中, W 是一个 $n \times r$ ($r < n$)的非负基图像矩阵, H 是一个 $r \times m$ 的非负编码系数矩阵,

收稿日期: 2005-07-19

作者简介: 蒲晓蓉(1969-),女,硕士,讲师,主要从事神经网络,生物特征识别等方面的研究。

\mathbf{H} 的每一列对应矩阵 \mathbf{V} 中的一个人脸样本。

文献[3]认为非负稀疏矩阵分解是一种基于局部特征的人脸表示方法, 利用该技术进行人脸识别更直观且更符合人的认知行为方式。通过非负稀疏矩阵分解, 使得 $\mathbf{E}(\mathbf{W}, \mathbf{H})$ 最小, 即:

$$\mathbf{E}(\mathbf{W}, \mathbf{H}) = \|\mathbf{V} - \mathbf{WH}\|^2 \quad (1)$$

式(1)应满足约束条件 $\text{sparseness}(\mathbf{w}_i) = \mathbf{S}_w, \forall i$ 和 $\text{sparseness}(\mathbf{h}_i) = \mathbf{S}_h, \forall i$, 其中 \mathbf{w}_i 是基矩阵 \mathbf{W} 的第 i 列, \mathbf{h}_i 是关系矩阵 \mathbf{H} 的第 i 行, \mathbf{S}_w 和 \mathbf{S}_h 分别表示 \mathbf{W} 和 \mathbf{H} 期望的稀疏度, 定义为 $\text{sparseness}(\mathbf{x}) = \frac{\sqrt{n} - (\sum |\mathbf{x}_i|) / \sqrt{\sum \mathbf{x}_i^2}}{\sqrt{n} - 1}$, n 是 \mathbf{x} 的维数, 当且仅当非负向量 \mathbf{x} 包含一个非零元素, 该函数值等于 1; 当且仅当 \mathbf{x} 中的所有元素都相等, 该函数值等于 0。

1.2 主成分分析

PCA方法通过提取原始图像空间中的主要特征(即主元)减少数据冗余, 将原始数据投影到一个低维的特征子空间进行处理, 既能保持原始数据的绝大部分信息, 又能解决数据空间维数过高导致处理代价高昂的问题。PCA方法通过主元提取, 找到一组特征脸(“eigenface”)基图像, 该基图像是一组标准正交的特征向量, 其中可以包含正、负或零像素值。

基于特征脸基图像, 可以计算出一组人脸样本 \mathbf{V} 的特征向量 \mathbf{F} , 即 $\mathbf{F} = \mathbf{W}_{\text{PCA}}^T (\mathbf{V} - \Psi)$, 式中 Ψ 是一组人脸样本的平均脸; $\mathbf{W}_{\text{PCA}} = [\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_r]$ ($r < m$) 是PCA特征脸基, 由相关矩阵 \mathbf{C} 中 “ r ” 个最大正交特征值 $\{\lambda_i | i=1, 2, \dots, r\}$ 对应的 “ r ” 个标准正交的特征向量构成。一组人脸样本 \mathbf{V} 的相关矩阵 \mathbf{C} 定义为 $\mathbf{C} = \frac{1}{m} \sum_{i=1}^m (\mathbf{V}_i - \Psi)(\mathbf{V}_i - \Psi)^T$ 。

2 Fisher线性判别式

如上所述, 非负稀疏矩阵分解和主成分分析方法都能将高维图像空间降到低维子空间, 主成分分析方法能将特征空间降到 $N-c$ 维, N 是样本中的人脸图像数量, c 是样本中的人脸类。上述两种方法都能使类间离散度最大化, 有利于分类; 但同时又能使类内离散度最大化, 不利于分类。Fisher线性判别式方法能找到易于分类的投影方向, 即找到一个使类间距离与类内距离比率最大的一维子空间^[4]。

Fisher线性判别子空间定义为:

$$\mathbf{W}_{\text{LDA}} = \arg \max_{\mathbf{W}} \frac{|\mathbf{W}^T \mathbf{S}_B \mathbf{W}|}{|\mathbf{W}^T \mathbf{S}_W \mathbf{W}|} = [\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_\mu]^T \quad (2)$$

式中 $\{\mathbf{W}_i | i=1, 2, \dots, \mu\}$ 是对应 \mathbf{S}_B 和 \mathbf{S}_W 中 $c-1$ 个最大特征值 $\{\lambda_i | i=1, 2, \dots, c-1\}$ 的一组判别式向量, 满足方程 $\mathbf{S}_B \mathbf{W}_i = \lambda_i \mathbf{S}_W \mathbf{W}_i$ ($i=1, 2, \dots, c-1$)。 \mathbf{S}_B 表示类间离散矩阵, 定义为 $\mathbf{S}_B = \sum_{i=1}^c N_i (b_i - \bar{b})(b_i - \bar{b})^T$, 式中 N_i 是训练样本中第 i 类 \mathbf{C}_i 中的样本数量, c 表示样本中类的数量, \bar{b} 表示总样本的均值, b_i 表示第 i 类的均值。类内离散矩阵 \mathbf{S}_W 定义为 $\mathbf{S}_W = \sum_{i=1}^c \sum_{b_k \in \mathbf{C}_i} (b_k - b_i)(b_k - b_i)^T = \sum_{i=1}^c \mathbf{S}_{W_i}$, 式中 \mathbf{S}_{W_i} 是类 \mathbf{C}_i 的相关矩阵。

3 基于Fisher非负稀疏矩阵分解的非完整人脸识别

文献[5]通过将Fisher线性判别式(Linear Discriminant Analysis, LDA)与非负稀疏矩阵分解方法结合起来, 构成基于Fisher的非负稀疏矩阵分解方法(Fisher's Non-negative Matrix Factorization with Sparseness Constraints, FNMFs)。该算法将非负稀疏矩阵分解得到的相关系数矩阵投影到Fisher子空间, 以便于分类。具体处理步骤如下: (1) 利用非负稀疏矩阵分解, 将一个训练集 \mathbf{V} 分解为一个非负基图像矩阵 \mathbf{W}_{NMF} 和一个非负编码系数矩阵 \mathbf{H}_{NMF} , 并适当地控制基图像 \mathbf{W}_{NMF} 的稀疏度, 即 $\mathbf{V}_{\text{train}} = \mathbf{W}_{\text{NMF}} \mathbf{H}_{\text{NMF}}$ 。(2) 将系数矩阵 \mathbf{H}_{NMF} 投影到Fisher子空间, 即 $\mathbf{S}_{\text{train}} = \mathbf{W}_{\text{LDA}}^T \mathbf{H}_{\text{train}}$ 。(3) 对任意待识别人脸 \mathbf{V}_{test} , 将其系数矩阵 \mathbf{H}_{test} 投影到Fisher子空间, 即 $\mathbf{S}_{\text{test}} = \mathbf{W}_{\text{LDA}}^T \mathbf{H}_{\text{test}}$, 式中系数矩阵 \mathbf{H}_{test} 经 $\mathbf{H}_{\text{test}} = \mathbf{W}_{\text{NMF}}^+ \mathbf{V}_{\text{test}}$ 计算获得, 式中 $\mathbf{W}_{\text{NMF}}^+$ 是基图像矩阵 \mathbf{W}_{NMF} 的伪逆矩阵。(4) 再计算 $\mathbf{S}_{\text{train}}$ 和 \mathbf{S}_{test} 的欧氏距离, 即 $\varepsilon^2 = \|\mathbf{S}_{\text{train}} - \mathbf{S}_{\text{test}}\|^2$ 。

为了测试该算法的性能,将PCA与Fisher线性判别式算法结合,与该算法进行性能对比,即首先将PCA子空间与Fisher子空间结合,构成一个新的子空间(简称PL子空间),得到 $\mathbf{W}_{\text{PL}}^T = \mathbf{W}_{\text{LDA}}^T \mathbf{W}_{\text{PCA}}^T$;然后将训练样本投影到PL子空间有 $\mathbf{X}_{\text{train}} = \mathbf{W}_{\text{PL}}^T (\mathbf{V}_{\text{train}} - \Psi)$;再将待识别图像 \mathbf{V}_{test} 投影到PL子空间有 $\mathbf{X}_{\text{test}} = \mathbf{W}_{\text{PL}}^T (\mathbf{V}_{\text{test}} - \Psi)$;最后,计算 $\mathbf{X}_{\text{train}}$ 与 \mathbf{X}_{test} 之间的欧氏距离。式中 Ψ 是训练样本的均值。

4 实验验证

本文利用NMF结合Fisher方法,验证对裁剪过的人脸图像的认识和恢复性能。实验基于UMIST标准人脸数据库^[6]。该人脸数据库包含20个人的564张包含不同种族和性别的被试的正面和侧面人脸图像,且图像尺寸不完全相同。实验随机选择20个被试的200张近似正面人脸图像,选择其中的100张作为训练集,每个被试5张;剩余的100张作为测试集,每个被试5张。训练集和测试集都是随机选取,被选中的200张图像首先被统一转换为 92×112 大小,然后进行不同程度的裁减,这将使训练和测试的所有图像不同程度地损失部分信息,如图1所示。实验将非负稀疏矩阵分解的维数“ r ”和PCA的特征数分别设置为10, 20, 30, 40, 50, 60, 70;非负稀疏矩阵分解的基图像的稀疏度设置为0.75,其迭代次数为800次。图2分别描述了两种算法对损失程度约21%和60%的人脸图像的正确识别率比较。

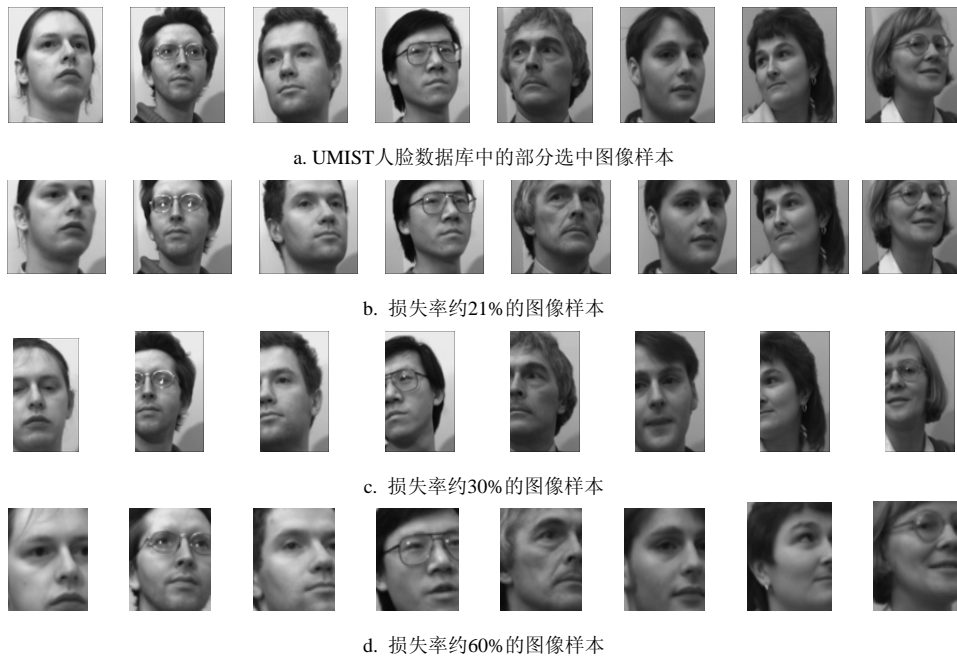


图1 UMIST人脸数据库中的部分选中图像样本及部分不同程度裁剪后的人脸样本




图2 新算法与PCA+Fisher算法对不同损失程度的人脸图像的认识率比较

(下转第220页)




图7 自适应神经模糊控制系统转矩仿真曲线




图8 三种控制方式下系统转速响应比较图

4 结论

将ANFIS控制应用于交流变频调速系统,能有效地利用人类知识处理不精确及不确定的情况,加强了对未知或变化的环境进行学习和调节的性能,对交流调速系统而言,在高性能应用场合,如无速度传感器低速下的控制,如果了解和考虑参数的实际变化规律,还可以大大缩小智能控制器的考虑范围,使控制进一步简化。

参 考 文 献

- [1] Jang J-S R. ANFIS: adaptive-network-based fuzzy inference system[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1993, 23(3): 665-685.
- [2] Tanaka K, Sugeno M. Stability analysis and design of fuzzy control system[J]. Fuzzy Set and Systems, 1992, 45: 135-156.
- [3] 丛 爽, 高雪鹏. 基于ANFIS的非线性电机系统的建模[J]. 基础自动化, 2002, 9(1): 6-8.
- [4] 柳朝军, 廖晓钟, 张宇河. 动态模糊神经网络控制器在伺服系统中的应用[J]. 控制与决策, 2001, 16(3): 347-350.

编辑 漆 蓉

(上接第210页)

5 结 论

实验证明,对部分残缺的人脸图像的识别,新算法的性能显著高于传统的PCA+Fisher子空间的性能。新算法结合非负矩阵分解和Fisher线性判别式方法,基于人脸的局部特征进行识别,对人脸图像的局部信息损失不太敏感。传统PCA方法基于人脸的全局特征进行识别,部分信息丢失将对其识别性能产生很大影响。该实验结果完全不同于对遮挡人脸进行的实验,作者将进一步研究这二者间存在差异的原因。

参 考 文 献

- [1] Lee D D, Seung H S. Learning the parts of objects by non-negative matrix factorization [J]. Nature, 1999, 401(6 755): 788-791.
- [2] Turk M A, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive. Neuroscience, 1991, 3:71-86.
- [3] Patrik O H. Non-negative matrix factorization with sparseness constraints [J]. Journal of Machine Learning Research, 2004, 5: 1 457-1 469.
- [4] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces versus fisherfaces: recognition using class specific linear projection [J]. IEEE Trans. Pattern Anal. Machine Intell., 1997, 19: 711-720.
- [5] Pu Xiaorong, Zhang Yi, Zheng Ziming, etc. Face recognition using fisher non-negative matrix factorization with sparseness constraints [J]. Lecture Notes in Computer Science, 2005, 3 497: 112-117.
- [6] The UMIST 人脸数据库[DB/OL]. <http://images.ee.umist.ac.uk/danny/database.html>, 2003-11-28.

编辑 熊思亮