

基于空间约束低秩图的人脸识别

杨国亮 谢乃俊 罗 璐 梁礼明

(江西理工大学电气工程与自动化学院 赣州 341000)

摘 要 低秩表示能够很好地揭示隐藏在数据中的全局结构信息并且对噪声具有很强的鲁棒性。基于图嵌入维数约简理论框架,提出了一种人脸识别算法,其利用低秩表示模型构建数据低秩图。此外,在低秩模型中引入数据空间约束项,构建一种具有空间约束的低秩图以提高识别效果。在 ORL 和 PIE 标准人脸数据库上进行实验,同传统的识别算法相比,结果显示所提出的算法在识别率和对噪声的鲁棒性上具有更好的表现。

关键词 低秩表示,空间约束项,低秩图,人脸识别

中图法分类号 TP391.41

文献标识码 A

DOI 10.11896/j.issn.1002-137X.2014.08.063

Low-rank Graph with Spatial Constraint for Face Recognition

YANG Guo-liang XIE Nai-jun LUO Lu LIANG Li-ming

(School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract The low-rank representation (LLR) model can reveal the subtle data structure information and show a strong robustness when dealing with noises. Based on the framework for graph embedding dimensionality reduction method, we proposed a face recognition algorithm which establishes low-rank graph using low-rank representation model. In addition, we constructed a novel low-rank graph with spatial constraint by using spatial information of the tracked points to improve recognition performance. To demonstrate the effectiveness of the presented algorithm, our comparative experiments were conducted using ORL and PIE face image databases. Experimental results show that the effectiveness and robustness to noises are always better than other state-of-the-art methods.

Keywords Low-rank representation, Spatial constraints, Low-rank graph, Face recognition

1 引言

随着社会对公共安全、信息安全和金融等领域的发展需求,人脸识别技术展现出巨大的应用前景,在机器视觉和图像处理领域得到了广泛的研究。近来,基于谱图嵌入理论^[1]的人脸识别算法得到人们的关注,图能够揭示隐含在高维数据集中的本质结构关系,具有一定的鉴别表达能力。因此,建图方法的合理对人脸识别算法的表现起到决定性的作用。

在传统的流形学习算法中,人们利用数据间的邻域关系构建 K 近邻图和 ϵ 近邻图来揭示数据间的结构信息。基于邻域图的经典人脸识别算法有局部保持投影 (Locality Preserving Projection, LPP)^[2] 和邻域保持投影 (Neighborhood Preserving Embedding, NPE)^[3],两者都是在构建数据邻域图后,利用谱图嵌入理论将数据映射到低维空间进行识别分类,数据在嵌入的过程中保持邻域结构关系图不变。邻域图是将数据的连接关系和连接权值构造步骤独立开来进行的,邻域参数 K 的选择是全局固定的,而且代表数据间紧密程度的连接权值仅仅由两点间的欧氏距离决定,因此基于邻域图的人脸

识别算法对噪声很敏感,鲁棒性不强。为此, Wright J 等在文献^[4]中提出了基于稀疏表示的 l_1 图。 l_1 图的目的是学习数据点在除己之外所有数据集下最稀疏的表示,通过凸优化理论求解,能够揭示数据点间的高阶信息,而且整个过程不需要设置参数,具有稀疏性、自适应邻域范围和鉴别能力强等优点。此外, Yang 还将稀疏表示直接用于分类^[5],在图像聚类、子空间分割、人脸识别领域成功地运用,但是 l_1 图是对每个数据点进行单独的学习,没有对数据进行全局联合的表示,当数据来自多个独立的子空间或存在受到较大污染的奇异数据时,稀疏表示识别算法会受到较大的影响。

Candès E J 等人从数据集由具有低秩性的“干净”数据和具有稀疏性的噪声数据叠加而成的角度提出了鲁棒主成分分析 (Robust Principal Component Analysis, RPCA)^[6],算法认为来自同一空间的数据具有结构和信息相识性,组成的数据矩阵具有低秩结构。在“干净”数据秩最小和噪声稀疏的约束下通过最优化理论恢复出数据的低秩成分和稀疏成分。RPCA 很好地解决了数据矩阵补全和恢复问题;在人脸识别领域,将 RPCA 用于数据的预处理,可使人脸识别算法不再受

到稿日期:2013-10-17 返修日期:2014-01-03 本文受国家自然科学基金项目(51365017, 61305019),江西省科技厅青年科学基金(20132bab211032)资助。

杨国亮(1973—),男,博士,副教授,主要研究方向为模式识别与图像处理、智能控制, E-mail: ygliang30@126.com; 谢乃俊(1989—),男,硕士,主要研究方向为模式识别与图像处理; 罗璐(1988—),女,硕士,主要研究方向为模式识别与图像处理; 梁礼明(1967—),男,硕士,副教授,主要研究方向为机器学习。

数据污染的影响,提高了鲁棒性。但是RPCA在数据来自多个子空间的情况下,数据低秩结构受到破坏。Liu G在RPCA的基础上引入字典,提出了低秩表示模型(Low Rank Representation, LRR)^[7],来学习数据在字典联合线性组合下的最低秩表示,其能够准确地学习来自多个独立子空间的数据结构,具有良好的数据全局结构表达能力,对噪声也具有很好的鲁棒性。目前,LRR在半监督识别、数据降维、特征提取、人脸识别、有监督学习方面得到了运用。文献[8-10]将LRR成功地运用到了半监督识别中,利用LRR学习出有标签数据和无标签数据的相识度,然后推算出无标签数据的类别标签,达到分类目的,得到了较好的实验结果。考虑到数据的局部结构信息,Zheng Y在LRR的基础上将局部正则约束项引入到半监督学习中,提出了局部约束低秩表示算法(LRRLC)^[11]。为了利用样本的标签信息在识别中的作用,Zhang N在LRR的基础上构建了数据样本的类内散度矩阵和类间散度矩阵,提出了基于LRR的鉴别投影(LLR-DP)^[12]算法并将其应用于特征提取。Arpit D将LRR作为约束项引入到基于稀疏表示的人脸识别中,提出了局部约束低秩编码人脸识别算法(LLRC)^[13]。

对于来自多个独立子空间的数据,已有的各种低秩表示算法表现出了很好的效果。但是现实世界中的数据,分布在不同子空间边缘的数据之间存在交集,各个子空间之间的独立性不强,这时,低秩表示模型学习出的数据低秩图中存在错误的连接信息。本文在低秩表示模型的基础上引入数据空间信息,构建具有较强的揭示数据全局结构能力和鉴别能力的低秩图,排除低秩图中的错误连接,增强低秩图揭示数据结构信息的能力,然后在谱图嵌入理论框架下对人脸图像进行识别。

2 低秩表示模型

有一数据集 $X=[x_1, x_2, \dots, x_n] \in R^{d \times n}$,采样于 l 个独立的子空间($l < n$), x_i 代表排列成列向量的人脸图像数据。现假设数据集 X 可以用字典 $A=[a_1, a_2, \dots, a_m]$ 线性组合表示成 $X=AZ$, $Z=[z_1, z_2, \dots, z_n]$ 是数据集 X 在字典 A 下的线性组合系数集, z_i 代表数据 x_i 在字典 A 下的线性组合系数向量。由于 $l < n$,数据集 X 中的某些人脸数据来自同一类别,具有相似性,因此,数据 X 在字典 A 下的线性表示系数 Z 具有低秩性。建立以下模型学习数据 X 在字典 A 下的最低秩表示 Z :

$$\min_Z \text{rank}(Z) \quad \text{s. t. } X=AZ \quad (1)$$

现实中同一人脸的多个图像数据往往采集于不同光照、表情和姿态的情况下,这些都会或多或少地对人脸数据产生干扰,这些干扰都会影响数据的低秩性。RPCA中将数据矩阵 X 分解成 $X=D+E$,其中 D 表示数据的“干净”成分, E 表示稀疏噪声,通过对“干净”数据的低秩约束和对噪声数据的稀疏约束,利用优化理论方法恢复出数据的“干净”成分 D 。在低秩表示模型中,为避免噪声干扰,同样将数据 X 表示成 $X=AZ+E$,低秩表示模型可以转换为:

$$\min_Z \text{rank}(Z) + \lambda \|E\|_0 \quad \text{s. t. } X=AZ+E \quad (2)$$

上述最优化问题是典型的非凸优化问题。近来在最优化理论中,在满足某些条件的情况下,用核范数 $\|Z\|_*$ 和 l_1 范数 $\|E\|_1$ 分别代替秩约束和稀疏约束。文献[14]中发现,当数据存在奇异点或受到大的污染时, $l_{2,1}$ 范数 $\|E\|_{2,1}$ 能够更

好地模型化噪声数据。因此,数据在字典下的最低秩表示可以通过求解下面的最优化问题:

$$\min_{Z,E} \|Z\|_* + \lambda \|E\|_{2,1} \quad \text{s. t. } X=AZ+E \quad (3)$$


式中 $\|E\|_{2,1} = \sum_{j=1}^n \sqrt{\sum_{i=1}^m ([E]_{ij})^2}$, $\|Z\|_* = \sum_i \sigma_i(Z)$,低秩表示模型求解得到的数据 X 在字典下的最低秩表示 Z 能够揭示数据的全局结构。

3 基于空间约束低秩图嵌入人脸识别算法

基于谱图嵌入理论框架下的人脸识别算法假设高维人脸图像数据的本质是低维流形嵌入在高维数据空间的结果。人脸数据间存在某种结构关系,这种关系可以通过图得到揭示。谱图嵌入理论认为这种数据结构关系在低维流形和高维嵌入空间中是保持一致的,所以可以将高维人脸数据降低到相应的低维本质子空间中进行识别分类。

3.1 低秩图

文献[15]证明了低秩表示系数矩阵 Z 代表的是数据的行空间信息, Z 中的元素 Z_{ij} 能够代表数据 X_i 和 X_j 之间的相似度。因此,当把数据集 X 自身作为字典 A ,低秩表示模型自动地学习数据点间的连接关系和连接权值,得到数据在全局重构下的最低秩表示 Z 。考虑到图的连接权值矩阵的对称特性,通过 $W=(Z+Z^T)/2$ 构建数据的低秩图。图1给出了低秩表示模型分别对人工合成数据和现实人脸数据构建的低秩图结构。图1中(a)是人工生成的5个不同独立子空间数据的低秩图,(b)是ORL人脸数据库中6类不同人脸数据的低秩图。



(a)人工生成数据低秩 (b)人脸数据低秩图

图1 不同数据的低秩图

3.2 具有空间信息约束的低秩图

3.2.1 欧氏空间信息约束项

图1显示了两种不同类型数据的低秩图,从图(a)可以发现当数据来自多个独立的子空间时,低秩表示模型能够准确地学习出子空间的个数,清楚地揭示了数据间的结构信息;然而,当我们的数据来自现实世界的人脸或者其他图像时,低秩表示也能够学习出子空间的个数,一定程度上揭示了数据的结构信息,但会受到位于空间边缘数据的干扰。从图1(b)中我们发现,分布在子空间边缘或两个子空间交界处的数据之间存在图结构上的连接,这种连接是错误的,给准确反映数据结构信息带来干扰。为了排除这一干扰,我们可以考虑将这部分干扰去除,即当不属于同一子空间的数据 X_i 和 X_j 在图结构上存在连接时,我们强制解除它们的这种连接关系,使得 $Z_{ij}=0$ 。假如事先知道数据来自哪一个子空间,这一干扰可以通过引入类别信息约束项解决。可是,现实中获得数据的类别信息是一项工作量非常大且相当耗时的工作,获得大量数据的类别信息不符合实际要求;另一方面,无类别标签的图

像数据大量存在,获取也较容易。因此,我们寻求其他的方法来排除人脸数据在低秩图中错误连接的干扰。

在流形学习中,为了度量两个样本间的相似程度,人们往往采用欧氏距离近似。在 d 维欧氏空间里,存在两个数据 $(x_i, x_j) \in R^d$, 欧氏距离是数据特征点在每个基坐标轴上的距离平均值 $d_{ij} = \|x_i - x_j\|_2$, 显然,如果两个数据点 i 和 j 来自同一类别的目标, d_{ij} 的值会很小; 当两个数据属于不同类别目标时, d_{ij} 的值会相应地更大。这样我们可以通过数据的空间欧氏距离信息,在低秩表示模型中引入如下的约束来避免数据低秩图中的错误连接; 我们构建约束项 $const = D \odot Z$, $\odot$ 表示数据矩阵元素间的点积, D 为空间信息约束矩阵。当数据 x_i 和 x_j 为同一类别数据时 (d_{ij} 较小), D 矩阵中的第 (i, j) 个元素值非常小; 当数据 x_i 和 x_j 数据属于不同类别数据时 (d_{ij} 较大), D 矩阵中的第 (i, j) 个元素值非常大,这就使得不同类别数据间的低秩稀疏 $Z_{ij} = 0$ 。上面讨论了欧氏距离在一定程度上反映了数据的相似性。因此,数据 i 和 j 之间的欧氏距离 d_{ij} 越大, D_{ij} 越小,反之亦然。径向基函数具有揭示这一特点的性质,我们采用径向基函数来构建约束矩阵 D , 对于两个数据点 (x_i, x_j) , 径向基函数 K_{ij} 有如下定义:

$$K_{ij} = \exp\left\{-\frac{\|x_i - x_j\|_2^2}{\lambda_k}\right\} \quad (4)$$

式中, λ_k 为径向基函数的核参数。定义 $D_{ij} = K_{ij}^{-1}$, 由于 $K_{ij} = K_{ji}$, 因此径向基函数构建的矩阵 D 是对称的。

算法 1 求解低秩表示模型的 LADMAP 算法

输入: 数据矩阵 X , 字典 D , 参数 $\lambda > 0$

初始化: $Z_0 = E_0 = Y_0 = 0, u_0 = 0.1, u_{\max} = 10^{10}, \rho_0 = 1.1, \epsilon_1 = 10^{-6}, \epsilon_2 = 10^{-2}, \eta_1 = \|A\|_2^2$

根据式(4)计算数据空间约束信息矩阵 D :

$$D_{ij} = K_{ij}^{-1};$$

While $\|X - AZ_k - E_k\|_F / \|X\|_F \geq \epsilon_1$ or $u_k \max(\sqrt{\eta_1} \|Z_k - Z_{k-1}\|_F, \|E_k - E_{k-1}\|_F) / \|X\|_F \geq \epsilon_2$ do

1. 更新 Z :

$$Z^* = \Theta_{(\eta_1 u_k)^{-1}}(Z_k + [A^T(X - AZ_k - E_k + Y_k/u_k)]/\eta_1);$$

$$Z_{k+1}^* = D \odot Z^*;$$

2. 更新 E :

$$E_{k+1}^* = \Omega_{\lambda u_k}^{-1}(X - AZ_{k+1}^* + Y_k/u_k);$$

3. 更新拉格朗日乘子 Y :

$$Y_{k+1}^* = Y_k + u_k(X - AZ_{k+1}^* - E_{k+1}^*);$$

4. 更新参数 u :

$$u_{k+1} = \min(u_{\max}, \rho u_k)$$

$$\rho =$$

$$\begin{cases} \rho_0, & u_k \max(\sqrt{\eta_1} \|Z_k - Z_{k-1}\|_F, \|E_k - E_{k-1}\|_F) / \|X\|_F < \epsilon_2; \\ 1, & \text{其他} \end{cases}$$

end while

输出: 低秩表示 Z

3.2.2 空间信息约束低秩图模型

在低秩表示模型的基础上引入数据的空间信息约束项, 构建下面新的空间约束低秩表示图模型:

$$\min_{Z, E} \|D \odot Z\|_* + \lambda \|E\|_{2,1} \quad \text{s.t. } X = XZ + E \quad (5)$$

式中, D 是数据的空间信息约束矩阵, 当数据 i 和 j 属于同一子空间数据的概率较大时, D_{ij} 的值相应较小, 反之亦然; $\odot$ 表示两相同大小矩阵相应位置元素间的点积; X 表示数据集本身组成低秩表示的字典。

优化问题可以通过增广拉格朗日方法 (Augmented La-

grange Multipliers, ALM) 求解得到最优化解 (Z^*, E^*) , 但是在 ALM 求解算法中需要引入两个辅助变量 M 和 Y , 在算法的每次迭代过程中都要对其进行计算和更新, 计算复杂。本文采用自适应惩罚线性交替方向法 (LADMAP)^[16] 求解上述优化问题。首先构建式(5)的增广拉格朗日函数:

$$\begin{aligned} L(Z, E, Y, u) &= \|D \odot Z\|_* + \lambda \|E\|_{2,1} + \langle Y, X - XZ - E \rangle + \frac{u}{2} \|X - XZ - E\|_F^2 \\ &= \|D \odot Z\|_* + \lambda \|E\|_{2,1} + h(Z, E, Y, u) - \frac{1}{2u} \|Y\|_F^2 \end{aligned} \quad (6)$$

其中, $h(Z, E, Y, u) = \frac{u}{2} \|X - XZ - E + Y/u\|_F^2$, Y 为拉格朗日乘子。采用交替更新策略, 固定其他参数, 通过最小化拉格朗日函数 L 分别对 Z, E 进行更新:

$$\begin{cases} Z^{k+1} = \arg \min_Z L(Z^k, E^k, Y^k, u_k) \\ E^{k+1} = \arg \min_E L(Z^{k+1}, E^k, Y^k, u_k) \end{cases} \quad (7)$$

$$\begin{aligned} Z_{k+1} &= \arg \min_Z L(Z_k, E_k, Y_k, u_k) \\ &= \arg \min_Z \|D \odot Z\|_* + \langle \nabla_Z h(Z_k, E_k, Y_k, u_k), Z - Z_k \rangle + \frac{\eta_1 u_k}{2} \|Z - Z_k\|_F^2 \end{aligned}$$

$$= \arg \min_Z \|D \odot Z\|_* + \frac{\eta_1 u_k}{2} \|Z - Z_k + [-X^T(X - XZ_k - E_k + Y_k/u_k)]/\eta_1\|_F^2 \quad (8)$$

$$\begin{aligned} E^{k+1} &= \arg \min_E L(Z^{k+1}, E^k, Y^k, u_k) \\ &= \arg \min_E \lambda \|E\|_{2,1} + \frac{u_k}{2} \|X - XZ_{k+1} + Y_k/u_k\|_F^2 \end{aligned} \quad (9)$$

式中, $\nabla_Z h(Z_k, E_k, Y_k, u_k)$ 为函数 h 关于参数 Z 的偏微分, $\eta_1 = \|X\|_2^2$ 。文献[17]中证明了 Z 参数的更新问题有解: $Z_{k+1}^* = \Theta_{(\eta_1 u_k)^{-1}}(Z_k + [X^T(X - XZ_k - E_k + Y_k/u_k)]/\eta_1)$, 其中算子 $\Theta_\epsilon(M) = US_\epsilon(\Sigma)V^T$, $U\Sigma V^T$ 代表矩阵 X 的奇异值分解; 由参考文献[7]可知: E 参数的最优化解 $E_{k+1}^* = \Omega_{\lambda u_k}^{-1}(X - XZ_{k+1} + Y_k/u_k)$, 其中, 当 $\epsilon < \|X_i\|_2$ 时, 算子 $\Omega_\epsilon(X)$ 的第 i 列为 $(1 - \epsilon/\|X_i\|_2)x_i$, 否则, $\Omega_\epsilon(X)$ 的第 i 列为零向量。在算法 1 中列出了空间信息约束项低秩图的求解步骤。

3.3 低秩图嵌入人脸识别框架

谱图嵌入理论是在保证数据的主要特征结构信息不丢失的前提下, 学习数据的本质低维子空间, 从而达到维数约简的目的, 整个学习过程中数据的低秩结构信息保持不变。为了达到这一目的, 数据在降维前后应该满足: 在高维空间中, 两个数据点 i 和 j 具有相近属性关系, 那么, 它们在相应的低维子空间中依然保持这种关系。我们构建下面的代价函数:

$$\epsilon(Y) = \frac{1}{2} \sum_{i,j=1}^n W_{ij} \|y_i - y_j\|_2^2 \quad (10)$$

式中, W_{ij} 是样本点 i 与样本点 j 之间的相识度权值, 即数据图结构中的连接权值; (y_i, y_j) 是样本点 (i, j) 在低维空间的表示。引入转换矩阵 P 将数据从高维映射到低维子空间中, 上面的代价函数转化为:

$$\begin{aligned} \epsilon(Y) &= \frac{1}{2} \sum_{i,j=1}^n W_{i,j} \|y_i - y_j\|_2^2 \\ &= \frac{1}{2} \sum_{i,j=1}^n W_{i,j} \|P^T x_i - P^T x_j\|_2^2 \\ &= \sum_{i=1}^n P^T x_i D_{ii} x_i^T P - \sum_{i,j=1}^n P^T x_i W_{ij} x_j^T P \end{aligned}$$

$$\begin{aligned}
&=P^T X(D-W)X^T P \\
&=P^T XLX^T P
\end{aligned} \quad (11)$$

式中, $X=[x_1, x_2, \dots, x_n]$ 为高维数据集; W 是数据低秩图连接矩阵, $W=(Z+Z^T)/2$; D 是一个对角矩阵, 对角线上的元素对应着 W 中相应列的总和, $D_{ii}=\sum_{j=1}^n W_{ij}$, $L=(D-W)$ 为拉普拉斯矩阵。增加约束条件 $P^T XDX^T P=1$, 优化如下代价函数:

$$\arg \min_p P^T XLX^T P \quad \text{s.t.} \quad P^T XDX^T P=1 \quad (12)$$

通过引入拉格朗日乘子解决最小特征值问题来解决最小化问题; 对式 $XLX^T P=\lambda XDX^T P$ 进行特征值分解, 取前 d 个最小特征值对应的特征向量组成转换矩阵 $P=[V_1, V_2, \dots, V_d]$, 通过映射关系 $y=P^T x$ 将高维数据映射到低维子空间中。接着, 在低维子空间中用最近邻法对人脸进行识别分类。基于低秩图嵌入人脸识别算法的主要步骤见算法 2。

算法 2 基于低秩图嵌入的人脸识别算法主要步骤

输入: 人脸训练数据集 X_{train} 及类别标签 L_{train} , 测试集 X_{test}

1. 通过算法 1 求解数据的低秩表示 Z ;
2. 由 Z 构建人脸数据集 X 的相似度低秩图矩阵 W , $W=(Z+Z^T)/2$, W 反映数据点之间的结构信息;
3. 通过谱图嵌入理论学习出数据从高位到低维子空间的转换矩阵 P :

$$\arg \min_p P^T XLX^T P \quad \text{s.t.} \quad P^T XDX^T P=1$$
4. 将训练数据和测试数据通过 P 转换到低维子空间:

$$Y_{\text{train}}=P^T X_{\text{train}}, Y_{\text{test}}=P^T X_{\text{test}}$$
5. 利用最近邻分类器在低维子空间对测试样本进行识别分类。

输出: 测试集图像标签 L_{test}

4 实验结果与分析

我们在 ORL 和 PIE 人脸数据库上进行实验, 同传统的 PCA、LPP、NPE、LRR 算法的实验结果进行对比分析, 验证算法的有效性。为了证明提出的算法对噪声的鲁棒性, 考虑了数据受噪声干扰的比例, 利用几种算法对不同受噪比例的数据进行识别分类, 比较几种算法对噪声的鲁棒性。此外, 我们还对算法中的噪声惩罚参数 λ 和高斯核参数 λ_k 设置不同的数值, 寻求最佳的参数范围。实验中, 我们将人脸库中的每张图片调整为 32×32 像素大小并且排列成 1024 维的列向量。

4.1 ORL 数据库

ORL 数据库由 40 个不同类别的人脸图像子集组成, 每个类别子集包含 10 张人脸图像, 这些图像是在不同光照, 不同时间, 不同表情等情况下采集而来的。我们在每个人脸子集中随机选择 5 张作为训练数据, 剩下的组成测试数据。我们提出的算法中设置噪声惩罚参数 $\lambda=0.18$, $\lambda_k=10^3$, LPP、NPE 算法中的邻域参数 $K=5$ 。通过上面的几种算法将数据降到不同维数的子空间中, 用最近邻分类器进行识别分类, 实验结果如图 2 所示。在 LRR 方法和本文算法中, 分别利用传统的低秩模型和本文构建的空间约束低秩模型得到数据低秩图结构, 然后利用谱图嵌入维数约简理论进行降维。其中基于保持全局结构信息的 LRR、PCA 和本文算法的整体表现优于基于保持局部信息结构的 NPE、LPP 算法, 说明了较于局部结构信息, 全局结构更能够准确揭示高维数据的结构。另外 ORL 人脸数据库包含多个类别的人脸图像, 存在多个流形结构也导致 NPE、LPP 算法的表现不是很好。引入局部空间约束的低秩图嵌入算法的识别结果明显好于其他几种算法, 同不具有空间约束的传统的 LRR 图方法相比, 平均识别率高出 10%, 最优识别率高出 7%, 证明了对于现实的人脸图像数

据, 局部约束项能够增强低秩表示模型对数据全局结构信息的揭示能力。




图 2 几种算法的识别结果

为了验证本文算法对噪声数据的鲁棒性, 数据集中分别随机选取不同比例的数据进行人为加噪, 然后进行识别实验。分别随机选取样本中 20%、40%、60% 和 80% 的数据加入均值 $\mu=0$ 、方差 $\sigma=0.01$ 的高斯噪声, 使得这部分数据在整个数据集中被视为受扰数据。图 3 是某张人脸受不同比例噪声干扰下的图像对照。将数据降到不同的维数子空间中, 利用最近邻分类器进行识别分类, 得到平均识别率。表 1 列出了几种算法对加入信噪比数据的平均识别率。表 1 中数据显示: 在数据集中加入不同比例的高斯噪声后, 算法相应的识别效果都受到了影响, 但是 LRR 方法和本文算法的下降幅度不明显, 在信噪比较低时, 识别效果基本保持不变, 验证了低秩图结构在识别中的鲁棒性。LPP 和 NPE 在数据降维的过程中, 保证的是数据的局部结构信息, 这种结构信息易受噪声干扰而受到破坏, 识别结果下降较多。





图 3 受噪声干扰图像

表 1 不同噪声比例数据下的各种算法平均识别率(%)

受噪数据的比例	PCA	LPP	NPE	LRR 方法	本文算法
原始	82.73	75.12	70.19	84.23	93.53
20%	70.58	70.82	65.52	84.03	93.47
40%	55.49	54.66	50.81	83.97	93.41
60%	48.27	42.79	46.73	83.54	93.39
80%	39.46	34.31	32.18	82.40	93.16

图 4 是 LRR 和本文算法在噪声惩罚参数 λ 取不同值时的最高识别率。图(a)显示: 在 LRR 算法中, 选取不同的惩罚参数会得到不同人的识别结果, λ 在 0.16~0.24 之间识别率最高。在图(b)中, 本文算法选取不同的 λ 值, 最后的识别结果变化不大, 参数 λ 值的选取范围更加广泛。



(a) LRR 算法

(b) 本文算法

图 4 不同参数 λ 取值下的识别率

(下转第 326 页)

ru from 1987 to 2010 [J]. Remote Sensing of Environment, 2014, 140: 165-178

- [6] Lillesand T M, Kiefer R W, Chipman J W. Remote sensing and image interpretation [M]. John Wiley & Sons Ltd, 2004
- [7] 徐佳, 关泽群, 何秀凤, 等. InSAR 大气误差改正中的空间插值研究[J]. 电子与信息学报, 2008, 30(4): 911-915
- [8] 葛咏, 梁怡, 马江洪, 等. 遥感影像配准误差传递模型及模拟分析[J]. 遥感学报, 2006, 10(3): 299-305
- [9] 潘励, 何潇. 环境减灾卫星 CCD 影像精纠正方法研究[J]. 武汉大学学报: 信息科学版, 2013, 38(6): 002

(上接第 300 页)

4.2 PIE 数据库

PIE 人脸数据库包含 68 类不同人脸的 41368 张人脸数据图像, 每类包含不同的表情、姿态和光照条件下的人脸数据, 我们选取 20 类, 每类随机选取 42 张图像组成我们的实验数据。在每类中分别选取 5、10、15 张图像组成训练集, 其余的作为测试集。不同训练样本数下的几种算法的最佳识别率和相应的低维子空间维数见表 2, 参与实验的 PIE 人脸图像主要在光照条件和姿态上存在变化, 几种算法能够取得较好的识别效果。随着参与训练样本数的增加, 算法的识别率表现得更好, 同时, 本文算法较其他几种算法有更好的识别效果。

表 2 几种算法在不同训练样本数下的识别率(%)

训练样本数(l)	PCA(维数)	LPP(维数)	NPE(维数)	本文算法(维数)
l=5	63.24(65)	91.89(65)	61.76(50)	63.11(65)
l=10	83.44(60)	93.44(75)	89.22(75)	98.13(60)
l=15	99.82(45)	95.19(75)	96.67(75)	100(25)

选择一个合适的核参数 λ_k 对构建数据的空间约束矩阵具有重要的作用。图 5 是 λ_k 取不同数值时的识别率。理论上, 一个较大的 λ_k 对数据的空间约束更加有效, 但是在利用空间约束矩阵和低秩表示点积之后, λ_k 值太大会减弱数据低秩特性在算法中发挥的作用, λ_k 值太小则会减弱空间约束项在算法中的作用。图 5 表明, 对于 λ_k , 算法具有较宽的选择范围, 即证明了算法对参数 λ_k 的选择不敏感。




图 5 本文算法不同 λ_k 参数下的识别率

结束语 在谱图嵌入理论框架下, 本文构建了一种具有空间信息约束项的低秩图用于人脸识别, 通过将数据空间信息项引入到低秩表示模型中, 构建具有很好的数据全局结构表达能力和较强的分类鉴别能力的数据低秩表示图用于人脸识别, 达到提高人脸识别效果的目的。在两个标准的人脸数据库上对本文提出的算法进行测试, 并同其他几种经典的人脸识别算法进行比较, 实验结果显示, 本文算法能够取得更好的识别结果, 对噪声数据表现得更加明显, 算法中参数选择具有较大的范围, 算法具有很好的鲁棒性。

参考文献

- [1] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2003,

- [10] 金绍华, 翟京生, 刘雁春, 等. 海底入射角对多波束反向散射强度的影响及其改正[J]. 武汉大学学报: 信息科学版, 2011, 36(9): 1081-1084
- [11] 杨永川, 杨轲, 王志浩, 等. 空间插值法在热环境流动观测中的应用[J]. 中南大学学报: 自然科学版, 2012, 43(9): 37-42
- [12] Chen Q, Wang S, Wang B, et al. Automatic Registration Method for Fusion of ZY-1-02C Satellite Images[J]. Remote Sensing, 2013, 6(1): 157-179
- [13] 郑磊, 杨德红, 孙德亮. GIS 技术在遥感数据管理中的应用[J]. 重庆邮电大学学报: 自然科学版, 2011, 25(3): 88-91

- [15(6): 1373-1396
- [2] Niyogi X. Locality preserving projections[C]//Neural Information Processing Systems. 2004, 16: 153
- [3] He X, Cai D, Yan S, et al. Neighborhood preserving embedding [C]//Tenth IEEE International Conference on Computer Vision, 2005 (ICCV 2005). IEEE, 2005, 2: 1208-1213
- [4] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227
- [5] 杨荣根, 任明武, 杨静宇. 基于稀疏表示的人脸识别算法[J]. 计算机科学, 2010, 37(9): 267-278
- [6] Candès E J, Li X, Ma Y, et al. Robust principal component analysis? [J]. Journal of the ACM (JACM), 2011, 58(3): 11
- [7] Liu G, Lin Z, Yu Y. Robust subspace segmentation by low-rank representation[C]//Proceedings of the 27th International Conference on Machine Learning (ICML-10). 2010: 663-670
- [8] Zhuang L, Gao H, Lin Z, et al. Non-negative low rank and sparse graph for semi-supervised learning[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2012: 2328-2335
- [9] Zhuang L, Gao H, et al. Semi-supervised classification via low rank graph[C]//2011 Sixth International Conference on Image and Graphics (ICIG). IEEE, 2011: 511-516
- [10] Yang S, Wang X, Wang M, et al. Semi-supervised low-rank representation graph for pattern recognition[J]. IET Image Processing, 2013, 7(2): 131-136
- [11] Zheng Y, Zhang X, Yang S, et al. Low-rank representation with local constraint for graph construction [J]. Neurocomputing, 2013, 122: 398-405
- [12] Zhang N, Yang J. Low-rank representation based discriminative projection for robust feature extraction [J]. Neurocomputing, 2013, 111: 13-20
- [13] Arpit D, Srivastava G, Fu Y. Locality-constrained Low Rank Coding for face recognition[C]//2012 21st International Conference on Pattern Recognition (ICPR). IEEE, 2012: 1687-1690
- [14] Xu H, Caramanis C, Sanghavi S. Robust PCA via outlier pursuit [J]. Systems Advances in Neural Information Processing Systems, 2010, 23: 2496-2504
- [15] Liu G, Lin Z, Yan S, et al. Robust recovery of subspace structures by low-rank representation [J]. Pattern Analysis and Machine Intelligence, 2012, 35(1): 172-184
- [16] Lin Z, Liu R, Su Z. Linearized alternating direction method with adaptive penalty for low-rank representation[C]//Advances in Neural Information Processing Systems 24 (NIPS 2011). 2011
- [17] Cai J F, Candès E J, Shen Z. A singular value thresholding algorithm for matrix completion[J]. SIAM Journal on Optimization, 2010, 20(4): 1956-198