

基于监督协同近邻保持投影的人脸识别算法

张其文 庄新磊

(兰州理工大学计算机与通信学院 兰州 730050)

摘要 基于流形学习理论的近邻保持嵌入算法(Neighborhood Preserving Embedding, NPE)能够发现数据集中隐含的内蕴结构,但当训练样本不足时,无法准确发现数据的内在流形结构,从而影响算法的识别效果。针对这一问题,对NPE算法进行改进,提出了监督协同近邻保持投影算法(Supervised Collaborative Neighborhood Preserving Projection, SCNPP)。该算法在类别信息的指导下构建近邻图,使同类样本间的几何关系得到保持,利用协同表示弥补NPE因样本不足造成的表示误差,以一个有效保持样本近邻关系、准确发现数据内在流形结构的权值矩阵计算投影矩阵,提高分类效果。在FERET、AR和Extended Yale B人脸数据集上的实验验证了该算法的有效性。

关键词 人脸识别,流形学习,近邻保持嵌入,协同表示,监督协同近邻保持投影

中图分类号 TP391.41 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.5.063

Supervised Collaborative Neighborhood Preserving Projection Based Algorithm for Face Recognition

ZHANG Qi-wen ZHUANG Xin-lei

(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract Neighborhood preserving embedding (NPE) algorithm based on manifold learning theory can discover the intrinsic structure behind data set. But in the scenery of face recognition, algorithm can't detect the intrinsic structure accurately due to the insufficient of data, sequentially, the performance of NPE is influenced. In order to solve the problems of NPE in face recognition, a supervised collaborative neighborhood preserving projection (SCNPP) algorithm was presented. The proposed algorithm constructs the neighborhood graph under the guidance of category information, makes the geometric relationship between the same samples be preserved effectually, utilizes the collaborative representation to remedy the representation errors of NPE caused by the lack of data, calculates the projection matrix with a weight matrix which preserves the neighborhood relationship effectually and discovers the intrinsic manifold structure of data accurately, improves the performance of classification. Extensive experiments on popular face databases (FERET, AR and Extended Yale B) verify the effectiveness of the proposed method.

Keywords Face recognition, Manifold learning, Neighborhood preserving embedding, Collaborative representation, Supervised collaborative neighborhood preserving projection

1 引言

人脸识别中,通常需要将人脸图像矩阵转换成向量形式,但会造成维数灾难(curse of dimensionality),因此必须对人脸图像进行降维,寻找其在低维空间中更紧致的表示,同时保持人脸图像之间隐藏的内在信息,以提高分类的准确率。经典的维数约简算法有主成分分析(Principal Component Analysis, PCA)和线性鉴别分析(Linear Discriminant Analysis, LDA), Turk和Belhumeur分别在这两种算法的基础上提出了特征脸(Eigenface)^[1]和Fisher脸(Fisherface)^[2]的人脸识别方法,取得了一定的成功。但是这两种方法都是线性的,对于非线性的人脸数据效果不够理想。

近年来,研究者发现人脸图像可能位于一个低维的非线性流形子空间中,并在此基础上提出流形学习理论。通过流

形学习算法可以将高维输入数据映射到低维流形子空间中,在降低数据维数的同时很好地保留了人脸样本间的空间结构信息。经典的流形学习算法有等距映射(Isometric Map, ISOMAP)^[3]、局部线性嵌入^[4]和拉普拉斯特征映射(Laplacian Eigenmaps, LE)^[5]等。但传统的流形学习方法缺乏明显的投影矩阵,无法对新加入的样本进行特征提取,即存在样本外点(out of sample)问题。为了解决这一问题,学者们开始了线性化经典流形学习算法的研究,相继提出局部保持投影(Locality Preserving Projection, LPP)^[6]和近邻保持嵌入(Neighborhood Preserving Embedding, NPE)^[7]等线性化流形学习算法。这些算法有效地保持了样本间的局部结构信息,并能够得到一个显式的投影矩阵,在模式识别问题中取得了较好的效果。然而流形学习算法需要充足的样本来发现数据的内在流形结构,众所周知人脸识别是一个典型的“小样本”问题,

到稿日期:2014-05-15 返修日期:2014-10-08 本文受甘肃省自然科学基金(2011GS04147),国家自然科学基金(61263047)资助。

张其文(1975-),男,副教授,硕士生导师,主要研究方向为 Ontology、智能信息处理技术、语义 Web、知识工程等;庄新磊(1989-),男,硕士,主要研究方向为人脸识别、稀疏表示, E-mail: zxl198907@163.com。

这影响了流形学习算法在人脸识别上的效果;此外,NPE算法的非监督性也限制了其在人脸识别中的性能。

在过去几年,稀疏编码和稀疏表示得到了迅速发展并成功应用于图像复原、压缩感知和图像超分辨率等领域。随后Wright等^[8]提出基于稀疏表示的分类器(Sparse Representation based Classification, SRC),将稀疏表示成功应用于人脸识别。该方法以全体训练样本作为过完备字典,求得测试样本在过完备字典上的稀疏表示系数,根据系数逐类计算重构残差,将测试样本划分到重构残差最小的类。受SRC启发,Cheng等^[9]在图嵌入理论的基础上提出了L1图的概念,将数据集的行为用稀疏表示来描述,并提出稀疏近邻保持嵌入等算法;郑等^[10]将线性鉴别分析的思想引入稀疏近邻保持嵌入,提出监督稀疏近邻保持嵌入(Supervised Sparse Neighborhood Preserving Projection, SSNPE)算法;Qiao等^[11]将稀疏表示中系数的稀疏性作为一种自然鉴别信息引入到特征提取中,提出稀疏保持投影(Sparsity Preserving Projection, SPP)算法;相等^[12]利用类别信息去除稀疏重建向量中分布在异类项的系数,提出监督稀疏保持投影(Supervised Sparsity Preserving Projection, SSPP);楼等^[13]结合稀疏表示与判别准则,在保持样本局部信息的同时最大化异类样本点间的距离,提出局部稀疏判别投影(Local Sparse Discriminant Projection, LSDP)算法。尽管SRC在人脸识别领域取得了令人瞩目的成果,并且推动了将稀疏表示应用到人脸识别领域的研究热潮,但它的工作机制并没有准确揭示。大多数研究过分强调基于L1范数的稀疏性在分类过程中的作用,但Zhang等^[14]的研究发现SRC中被忽视的协同表示(Collaborative Representation)才是SRC取得成效的关键所在。协同表示即来自不同个体的人脸图像共同表示测试样本,有效利用不同个体人脸图像之间的相似性解决了人脸识别中样本不足的问题,使样本得到更加准确的表示,提高了分类效果。

针对NPE算法在人脸识别中存在的问题,提出一种监督协同近邻保持投影算法。算法在类别信息的指导下构建近邻图,通过流形表示系数保持同类样本间的局部近邻关系,以近邻图外样本点为过完备字典协同表示NPE由于样本不足造成的表示残差,将二者结合得到一个有效保持近邻关系、准确发现数据内在流形结构的表示权值矩阵,能在投影过程中更好地保持原始数据在样本空间中的结构信息,提高分类效果。在开放人脸数据集FERET、AR和Extended Yale B上的实验结果验证了算法的有效性。

2 相关工作

2.1 稀疏表示与协同表示

2.1.1 稀疏表示

给定高维空间中人脸图像的训练样本集 $X = \{x_1, x_2, \dots, x_N\}$, $x_i \in R^D$,稀疏表示就是以 X 作为一个过完备字典,对于任意一个测试样本 x_i ,都可以找到分解最为稀疏的一组原子 s_i 并满足:

$$\min_{s_i} \|s_i\|_0 \quad \text{s. t. } x_i = Xs_i \quad (1)$$

其中, $\|s_i\|_0$ 表示 s_i 的L0范数,其意义为 s_i 中非零元的个数。众所周知,L0范数的组合最小化求解是NP难问题,在

实际应用中很难实现。

文献[8]中指出,如果 s_i 解足够稀疏,L0范数最小化问题与L1范数最小化问题拥有相同解,而L1范数最小化问题可以通过线性规划在多项式时间内得到解决。在此基础上提出用L1范数取代L0范数的近似解决方法,即:

$$\min_{s_i} \|s_i\|_1 \quad \text{s. t. } x_i = Xs_i \quad (2)$$

2.1.2 协同表示

在稀疏表示中有两个关键点,一是系数向量 s_i 被加上了基于L1范数的稀疏约束;二是将所有的样本点的集合 X 作为过完备字典,用字典中基元(即样本点)的线性组合表示样本点。之前大部分研究将稀疏表示在人脸识别中的成功归功于基于L1范数的稀疏性,而忽略了样本间协同表示的重要性。

Zhang等^[15]指出当 $\epsilon(\|s_i\|_p \leq \epsilon)$ 很小时,非稀疏的L2范数在增强样本表示的鉴别性方面有着同L0或L1相类似的效果,而样本间的协同表示才是稀疏表示取得成效的关键所在。从图1中可以看出,在人脸识别中,不同个体的人脸图像之间具有一定的相似性,而稀疏表示正是利用这些相似性,在过完备字典上更加准确地表示了人脸样本,很大程度上解决了人脸识别中的“小样本”问题,正是这种样本之间的协同表示大大促进了SRC的分类能力。



(a) Extended Yale B 数据库中第 32 类人脸图像



(b) Extended Yale B 数据库中第 5 类人脸图像

图1 不同个体人脸图像间的相似性

2.2 近邻保持嵌入

近邻保持嵌入(NPE)算法是局部线性嵌入(LLE)算法的线性近似。根据流形的局部平滑性特点,算法认为高维采样点的每个局部邻域都分布在一个局部线性片上(Linear patch),并用每个点的近邻重构系数来刻画该局部线性片的性质,通过在低维嵌入空间中保持每个点的近邻重构系数来保持整个数据的流形结构。

给定高维空间中人脸图像的训练样本集 $X = \{x_1, x_2, \dots, x_N\}$, $x_i \in R^D$,近邻保持嵌入算法的目的就是寻找一个变换矩阵 A ,通过变换 $y_i = A^T x_i$,把数据集 $X = \{x_1, x_2, \dots, x_N\}$ 投影到一个相对低维的空间 R^d ($d \ll D$)中,获得样本集 X 在低维空间中的投影点集 $Y = \{y_1, y_2, \dots, y_N\}$ 。近邻保持嵌入算法的基本步骤如下:

1)构建邻域图。在高维输入空间,通过欧氏距离寻找每个样本点的 k 近邻,令 $N(x_i)$ 表示样本点 x_i 的邻域集合。

2)计算重建权值。样本集中每一样本点可以通过它 k 近邻的线性组合进行重建,重建权值 w_{ij} 通过最小化目标函数(3)得到,约束条件①若 $x_j \notin N(x_i)$, $w_{ij} = 0$;② $\sum_j w_{ij} = 1$ 。

$$J(W) = \sum_i \|x_i - \sum_j w_{ij} x_j\|^2 \quad (3)$$

3)计算变换矩阵。此时保持线性重构权值矩阵 $W = (w_{ij})$,最小化在嵌入空间中每个样本点的重构误差。因此,变换矩阵 A 可以通过最小化式(4)获得:

$$J(A) = \sum_i \| A^T x_i - \sum_j w_{ij} A^T x_j \|^2 \quad (4)$$

简单的代数变换后,有

$$J(A) = A^T X M X^T A \quad (5)$$

其中, $M = (I - W)^T (I - W)$,约束条件为 $A^T X X^T A = I$ 。

最终转化为求解式(6)的广义特征值问题:

$$X M X^T a = \lambda X X^T a \quad (6)$$

式(6)的 d 个最小非零特征值所对应的特征向量 a_1, a_2, \dots, a_d 构成变换矩阵 A 。

近邻保持嵌入算法建立在样本采样充足的基础上,利用近邻重构系数来刻画样本的局部空间信息,通过最小化每个样本点的近邻表示误差获取重构权值矩阵。但人脸识别是一个典型的“小样本”问题,样本点可能无法通过其近邻点准确表示,即式(3)中最小二乘问题将得到一个较大的最优解,而在投影过程中并没有考虑这些表示误差,使得算法保持了不准确的局部结构信息,无法在嵌入空间准确恢复数据流形结构,从而影响算法效果。

3 本文算法

3.1 监督协同近邻保持投影

基于不同个体人脸图像位于不同低维子流形的事实,本文在 NPE 算法的基础上提出监督协同近邻保持投影算法。算法首先在类别信息的指导下构建近邻图;然后通过流形表示系数保持同类样本间的局部近邻关系,对于样本不足造成的表示残差,以近邻图外样本点为过完备字典协同表示,约束协同表示系数和为 0,降低在低维子空间中近邻图外样本点对于重建样本点的影响,将两者结合得到表示权值矩阵;最后在表示权值矩阵的基础上计算投影矩阵 A 。

给定人脸图像的样本集 $X = \{x_1, x_2, \dots, x_N\}$,其中 $x_i \in R^D$, D 表示原始数据的维数。样本集 X 分为 C 类, $\sum_{i=1}^C N_i = N$,其中 N_i 表示第 $i(i=1, 2, \dots, C)$ 类样本的数量。样本集 X 在 $d(d \ll D)$ 维空间的投影点集为 $Y = \{y_1, y_2, \dots, y_N\}$,其中 $y_i = A^T x_i \in R^d$ 。算法主要分为以下几步:

(1)构建近邻图

人脸识别中不同个体的人脸图像位于不同低维子流形上,对于样本集 X 中每一样本点 x_i 在构建邻域图时引入类别信息,在其同类样本点集 X_i 中构建 k 近邻图,使同类样本点间的几何关系得到更好的保持。设 $N(x_i)$ 为 x_i 的近邻集合, $N^-(x_i) = N - N(x_i)$ 为近邻图外样本点的集合。

(2)计算重建权值矩阵

a)计算流形表示系数:根据流形的局部平滑性特点,样本点 x_i 可以通过它的 k 近邻样本点线性表示。流形表示系数 m_{ij} 通过最小化目标函数(7)得到。

$$J(M) = \sum_i \| x_i - \sum_{x_j \in N(x_i)} m_{ij} x_j \|^2 \quad (7)$$

s. t. if $x_j \notin N(x_i), m_{ij} = 0$

$$\sum_j m_{ij} = 1$$

b)计算流形表示残差:由于没有充足的人脸图像样本,样

本点 x_i 无法通过其 k 近邻准确表示,即式(7)中的最小二乘问题将得到一个较大的最优解。

用矩阵 $R = \{r_1, r_2, \dots, r_N\}$ 代表流形表示残差,其中 $r_i (i=1, 2, \dots, N)$ 表示样本点 x_i 通过其 k 近邻线性表示的残差,则

$$r_i = x_i - X m_i^T \quad (8)$$

c)计算残差协同表示:以样本点 x_i 近邻图外的样本点协同表示流形表示残差,在利用人脸图像间相似性准确表示样本点 x_i 的同时,约束协同表示系数的和为 0,降低了不同个体人脸图像在降维过程中对样本点的影响,这是因为残差的协同表示系数相对于流形表示系数非常小。

对于表示误差矩阵 R 中每一列 $r_i (i=1, 2, \dots, N)$,以集合 $N^-(x_i)$ 中元素组成矩阵 X^- 作为过完备字典,求解 r_i 在字典 X^- 上的协同表示:

$$\min_{s_i} \| s_i \|_1 \quad \text{s. t. } r_i = X^- s_i, 0 = 1^T s_i \quad (9)$$

d)计算整体重建权值:将样本点 x_i 的流形表示系数 m_i 与残差的协同表示系数 s_i 结合得到整体重建权值 w_i ,即

$$w_i = m_i^T + s_i \quad \text{s. t. } \sum_j w_{ij} = 1 \quad (10)$$

进一步获得样本点的整体重建权值矩阵 W 。

(3)计算投影矩阵

通过保持线性重构权值矩阵 W ,最小化在嵌入空间中每个样本点的重建误差,变换矩阵 A 可以通过式(11)中目标方程获得:

$$\min_A \sum_i \| A^T x_i - A^T X w_i \|^2 \quad (11)$$

设 e_i 为第 i 个元素为 1 的 n 维单位向量,经过简单的代数变换,有

$$\begin{aligned} & \sum_i \| A^T x_i - A^T X w_i \|^2 \\ &= A^T \sum_i \| x_i - X w_i \|^2 A \\ &= A^T \sum_i (x_i - X w_i)(x_i - X w_i)^T A \\ &= A^T \sum_i (X e_i - X w_i)(X e_i - X w_i)^T A \\ &= A^T X (I - W^T - W - W W^T) X^T A \end{aligned} \quad (12)$$

为避免退化解,增加约束条件 $A^T X X^T A = 1$,式(11)可以转化为

$$\max_A \frac{A^T X V X^T A}{A^T X X^T A} \quad (13)$$

其中, $V = W^T + W - W W^T$ 。

最终转化为求解下面的广义特征值问题:

$$X V X^T A = \lambda X X^T A \quad (14)$$

式(14)的 d 个最大特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ 所对应的特征向量构成投影矩阵 $A \in R^{N \times d}$ 。

3.2 算法分析

在人脸识别中,样本空间的低维嵌入为多流形结构,每类样本对应一个低维子流形^[16],也就是不同个体人脸图像来自于不同的低维子流形,而在样本空间来自不同个体的人脸图像相互混杂。NPE 算法由于自身的非监督性,无法发现不同个体所在的低维子流形,因此所获得的低维子空间为单流形结构,分类效果并不理想。本文算法引入类别信息指导近邻图的构建,在降维过程中保持样本空间中同类样本间的几何关系,发现不同个体嵌入在样本空间的低维流形结构,使获得

的低维子空间呈现多流形结构,增强子空间的鉴别能力。

NPE算法需要建立在样本采样充足的基础上,但人脸识别是一个典型的“小样本”问题,样本点无法通过其近邻点的线性组合准确表示,使得流形结构在降维过程中发生形变,无法在嵌入空间准确恢复数据的流形结构。本文算法的重建权值由两部分组成,一是流形表示系数 m ,它基于流形学习的思想保持同类样本间的几何关系,发现个体所在的流形结构;二是协同表示系数 s ,它利用人脸图像间的相似性,以近邻图外的样本点集作为过完备字典,协同表示流形表示中由于采样不充足造成的表示误差,使样本空间中的样本点得到更准确的表示。因此本文算法发现个体所在流形结构的同时,准确记录样本空间中样本点在流形结构上的位置,减轻降维过程中流形结构发生的形变,在嵌入空间中更加准确地恢复数据的流形结构。

不同于NPE算法,本文算法包含两部分分别计算的权值,将这两部分权值有效结合是保证算法思想实现的关键。由于流形表示系数 m 用于保持同类样本间的几何关系并发现个体所在的流形结构,为了保持流形结构上样本点间的关系,在整体重建权值中 m 需要占绝对的比重;而协同表示系数 s 用于降低表示误差并准确记录样本点在流形结构上的位置,为了准确恢复出低维嵌入流形, s 除了降低表示误差之外,更重要的是不能对流形上样本点间的关系产生影响。因此约束 $\sum_j m_{ij} = 1$,即

$$x_i = m_{i1} \cdot x_1^m + m_{i2} \cdot x_2^m + \dots + (1 - m_{i1} - \dots - m_{i(k-1)}) \cdot x_k^m$$

其中, x_i^m 表示 k 近邻图中的第 i 个样本向量。同时约束 $\sum_j s_{ij} = 0$,即

$$r_i = s_{i1} \cdot x_1^{out} + s_{i2} \cdot x_2^{out} + \dots + 0 \cdot x_i + \dots - (s_{i1} + \dots + s_{i(N-k-2)}) \cdot x_{i(N-k-1)}^{out}$$

其中, x_i^{out} 表示近邻图外的第 i 个样本向量, r_i 表示样本点 x_i 经流形表示后的残差。

将流形表示系数与协同表示系数结合,组成整体重建权值 w_i ,即

$$w_i = X w_i = [X^m, X^{out}] \cdot [m_{i1}, m_{i2}, \dots, (1 - m_{i1} - \dots - m_{i(k-1)}), s_{i1}, s_{i2}, \dots, -(s_{i1} + \dots + s_{i(N-k-2)})]^T$$

其中, X^m 代表由样本点 x_i 近邻图内样本点组成的矩阵,而 X^{out} 代表由样本点 x_i 近邻图外样本点组成的矩阵。

由于 X^m 与 X^{out} 互斥,在结合成整体重建权值 w_i 的过程中 m_i 与 s_i 并未发生变化,确保了权值 w_i 能够准确发现数据的内在流形结构;另外由于残差 r_i 中的每一维都显著小于样本点 x_i 中的相应维,使得 s_i 中的非零项比 m_i 中的项都小,这样降低了降维过程中不同个体人脸图像对于重建样本点 x_i 的影响。此外,在这样的约束条件下,经结合得到的整体重建权值满足 $\sum_j w_{ij} = 1$,这使得权值 w_i 对于平移、旋转以及缩放具有不变性和更好的鲁棒性。

4 实验结果

为了验证算法的性能,分别是在开放的人脸数据集 FERET^[17]、AR^[18]和 Extended Yale B^[19,20]上进行了实验,根据

识别率评估算法的性能。同时与局部保持投影(LPP)^[6]、近邻保持嵌入(NPE)^[7]、监督稀疏近邻保持嵌入(SSNPE)^[10]、监督近邻保持嵌入(SNPE)(即在同类样本中构建近邻图的NPE)、稀疏保持投影(SPP)^[11]、监督稀疏保持投影(SSPP)^[12]和局部稀疏鉴别投影(LSDP)^[13]等线性化方法进行了对比实验。

4.1 数据集与预处理

FERET人脸数据集包含1565人的13539幅人脸图像,分别是在不同光照、表情和姿态变化以及不同时间跨度情况下采集的。实验选取一个包含200个人,每人7幅共1400幅图像的子集作为实验样本集。AR人脸数据集包含126人的4000多幅正面人脸图像,分别是在不同光照、表情和部分遮挡情况下采集的。实验选取120个人,每人14幅共1680幅图像作为实验样本集。Extended Yale B人脸数据集包含38人的2432幅正面图像,分别是在64种光照条件下采集的。实验选取20个人,每人27幅共540幅图像作为实验样本集。裁剪人脸图像将图像大小调整为32pixel×32pixel,并将图像灰度值归一化到[0,1]范围。图2为样本集中部分人脸图像。



(a) FERET 数据集的部分样本



(b) AR 数据集的部分样本



(c) Extended Yale B 数据集的一些样本

图2 部分实验人脸样本

4.2 实验设定与参数选择

实验分为训练和识别两个阶段,在训练阶段每人首先随机选取 l 幅图像作为训练样本集,FERET、AR和 Extended Yale B中 l 分别设定为{4}、{3,5,7}和{9,11,13};然后训练样本集上根据各算法的步骤计算投影矩阵 A ;最后利用投影矩阵 A 将训练样本投影到低维子空间。在识别阶段,经过预处理的测试图像利用投影矩阵 A 投影到低维子空间,使用最近邻分类器(NN)进行分类。

对于基于流形学习的方法(LPP、NPE、SNPE、LSDP、SC-NPP),分别在近邻参数 $k=\{1,2,\dots,l-1\}$ 情况下进行实验并选取最优结果作为该方法的识别率。LPP算法中的热核宽度 t 设置为2。SPP与SCNPP算法中使用 $l1_l2s$ 工具包^[21]计算稀疏表示系数。为了避免小样本问题同时确保SPP与SCNPP在过完备情况下实施,将原始数据经过PCA降维后再用于实验。以PCA-ratio表示原始数据经PCA处理后保持的能量,对于FERET、AR和 Extended Yale B数据集,PCA-ratio分别取98%、99%和99.5%。

4.3 实验结果与分析

图3—图5分别给出在FERET($l=4$)、AR($l=7$)和 Ex-

tended Yale B($l=13$)数据集上各算法识别率相对于维数的函数曲线。从中可以看出,非监督的 LPP、NPE 算法的识别效果较差,非监督的 SPP 算法由于自身的自然鉴别性取得了较好的识别效果。SSNPE 算法在 AR 和 Extended Yale B 数据集上的识别率低于 SPP 算法,而在 FERET 数据集上,由于流形学习相对于稀疏表示对姿态变化具有更好的鲁棒性,因此识别效果优于以稀疏表示为基础的 SPP、LSDP 算法。SSPP 算法利用类别信息删除权向量上位于异类项的系数,使同类样本间的关系得到更好的保持,识别效果高于 SSPP 算法,但由于表示误差增大,识别率低于 SNPE 算法。LSDP 算法在近邻图内稀疏表示样本点,同时增大近邻图内异类样本点的距离,识别效果优于 SNPE 算法,但是由于在近邻图内表示样本点具有较大的误差,因此识别效果低于 SCNPP 算法。本文算法 SCNPP 借助类别信息,通过流形学习发现并保持同类样本间的几何关系,同时引入协同表示降低 NPE 算法中的表示误差,更加准确地保持数据的内在流形结构,因此在 3 类数据集上均取得了优于其它算法的识别效果。




图3 FERET数据集上识别率与维数的函数关系($l=4$)




图4 AR数据集上识别率与维数的函数关系($l=7$)




图5 AR数据集上识别率与维数的函数关系($l=13$)

表1和表2分别给出在AR($l=\{3,5,7\}$)和Extended Yale B($l=\{9,11,13\}$)数据集上训练样本数量不同时各算法的平均识别率及相应维数和参数。从中可以看出,LPP算法和NPE算法由于自身的非监督性,当训练样本数量减少时,对于流形的逼近效果受到影响,识别率下降,而NPE算法的

下降幅度要明显高于LPP算法,这是由于表示误差的大幅度增加。基于稀疏表示的SSNPE、SPP、SSPP和LSDP算法,在训练样本减少时,由于稀疏表示所具有的鉴别性下降,识别效果均出现较大幅度的下降。SNPE和SCNPP算法由于在同类样本集内构建近邻图,在样本数量较少时(如表1第一栏)仍能发现数据的内在流形结构,使嵌入空间呈多流形结构,但SCNPP算法由于利用协同表示降低流形表示误差,能够更好地恢复出数据流形;虽然在样本数量较少时,可用于协同表示的样本减少,削弱了算法降低流形表示残差的能力,识别率有所降低,但该算法仍取得优于其它算法的识别效果。

表1 AR数据集上各类算法的识别率及相应维数和参数

Method	Number of train samples		
	3	5	7
LPP	58.71(236, k=3)	62.50(236, k=2)	71.67(290, k=2)
NPE	66.29(252, k=2)	74.81(258, k=4)	78.10(300, k=5)
SSNPE	67.35(168)	76.02(188)	80.24(287)
SPP	82.65(150)	85.00(151)	86.79(143)
SSPP	83.03(160)	86.11(185)	88.10(147)
SNPE	84.14(154, k=2)	88.43(120, k=5)	90.12(105, k=5)
LSDP	82.12(72, k=2)	88.61(72, k=4)	90.71(169, k=6)
SCNPP	87.12(130, k=5)	91.57(91, k=4)	93.21(111, k=4)

表2 Extended Yale B数据集上各类算法的识别率及相应维数和参数

Method	Number of train samples		
	9	11	13
LPP	65.82(179, k=5)	77.27(182, k=10)	85.71(198, k=3)
NPE	76.09(168, k=7)	83.90(186, k=9)	88.96(198, k=12)
SSNPE	84.51(92)	88.64(180)	90.48(172)
SPP	88.72(134)	90.53(140)	91.99(181)
SSPP	89.06(107)	91.67(119)	93.07(90)
SNPE	90.07(97, k=7)	92.23(87, k=10)	94.16(95, k=10)
LSDP	90.40(112, k=8)	92.61(105, k=10)	94.37(122, k=12)
SCNPP	91.92(91, k=7)	94.13(101, k=7)	96.10(111, k=9)

表3和表4分别给出在AR($l=7$)和Extended Yale B($l=13$)数据集上选取不同参数 k 时SNPE算法和SCNPP算法的识别率及相应维数。从中可以看出,对于同样在类内样本中构建近邻图的SNPE算法,在选择不同参数 k 时,SCNPP算法均能取得优于SNPE算法的识别效果,说明协同表示的引入能够降低流形表示误差,使算法更加准确地恢复数据的内在流形结构,提高识别效果。

表3 AR数据集上选择不同参数时的识别率及相应维数

Method	Different selection of parameter k					
	1	2	3	4	5	6
SNPE	82.74 (142)	86.43 (120)	88.10 (98)	89.76 (119)	91.12 (105)	91.00 (74)
SCNPP	83.45 (183)	90.24 (81)	91.79 (67)	93.21 (111)	92.14 (77)	91.31 (111)

表4 Extended Yale B数据集上选择不同参数时的识别率及相应维数

Method	Different selection of parameter k					
	1	3	5	7	9	11
SNPE	88.53 (130)	91.77 (105)	93.07 (108)	93.29 (97)	93.94 (89)	93.94 (87)
SCNPP	91.34 (125)	93.07 (111)	94.81 (87)	96.10 (111)	95.89 (96)	95.24 (92)

结束语 作为典型的线性化流形学习算法,NPE被成功应用于多个领域。然而,将NPE用于人脸识别时,由于样本不足,无法准确发现数据的内在流形结构,从而影响了算法的

效果。本文提出一种监督协同近邻保持投影算法,算法在类别信息的指导下构建近邻图,保持同类样本间的近邻关系,使嵌入空间呈多流形结构,对于表示过程中由于样本不足造成的表示误差,以近邻图外样本点集为过完备字典,利用人脸图像间的相似性协同表示这个误差,更加准确地表示了数据空间中样本点间的关系,准确发现数据的内在流形结构,提高了分类效果。实验表明:协同表示能够降低 NPE 中存在的表示误差,SCNPP 能够更加准确地发现数据流形结构,提高分类效果。

参 考 文 献

[1] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of cognitive neuroscience, 1991, 3(1): 71-86

[2] Belhumeur P N, Hespanha J P, Kriegman D. Eigenfaces vs. fisherfaces; Recognition using class specific linear projection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720

[3] Tenenbaum J B, Desilva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(5500): 2319-2323

[4] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326

[5] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural computation, 2003, 15(6): 1373-1396

[6] He Xiao-fei, Yan Shui-cheng, Hu Yu-xiao, et al. Face Recognition Using Laplacianfaces[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340

[7] He Xiao-fei, Cai Deng, Yan Shui-cheng, et al. Neighborhood preserving embedding[C]//Proceedings of the Tenth IEEE International Conference on Computer Vision, Beijing, China; IEEE Computer Society, 2005

[8] 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

[9] Cheng Bin, Yang Jian-chao, Yan Shui-cheng, et al. Learning with l1-graph for image analysis[J]. IEEE transactions on image processing; a publication of the IEEE Signal Processing Society,

2010, 19(4): 858-866

[10] 郑浩, 金忠. 一种有监督的稀疏保持近邻嵌入算法[J]. 计算机工程, 2011, 37(16): 155-157

[11] Qiao Li-shan, Chen Song-can, Tan Xiao-yang. Sparsity preserving projections with applications to face recognition[J]. Pattern Recognition, 2010, 43(1): 331-341

[12] 相文楠, 赵建立. 监督型稀疏保持投影[J]. 计算机工程与应用, 2011, 47(29): 186-188

[13] 楼宋江, 赵小明, 张石清. 一种局部稀疏判别投影算法[J]. 光子·激光, 2013, 24(7): 1406-1409

[14] Zhang Lei, Yang Meng, Feng Xiang-chu. Sparse representation or collaborative representation: Which helps face recognition? [C]//Proceedings of the 2011 International Conference on Computer Vision. Barcelona, Spain: IEEE Computer Society, 2011: 471-478

[15] Zhang Lei, Yang Meng, Feng Xiang-chu, et al. Collaborative representation based classification for face recognition[J]. arXiv preprint arXiv:1204. 2358, 2012

[16] Lu Gui-fu, Lin Zhong, Jin Zhong. Face recognition using discriminant locality preserving projection based on maximum margin criterion[J]. Pattern Recognition, 2010, 43(12): 3572-3579

[17] Phillips P J, Hyeonjoon M, Rizvi S A, et al. The FERET evaluation methodology for face recognition algorithms [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(10): 1090-1104

[18] Martinez A M, Benavente R. The AR face database [R]. CVC Technical Report, 1998

[19] Georghiadis A S, Belhumeur P N, Kriegman D. From few to many: Illumination cone models for face recognition under variable lighting and pose[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(6): 643-660

[20] Lee K C, Ho J, Kriegman D. Acquiring linear subspaces for face recognition under variable lighting[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(5): 684-498

[21] Huang Jun-zhou, Huang Xiao-lei, METAXAS D. Simultaneous image transformation and sparse representation recovery[C]//Proc. of the 2008 IEEE Conference on Computer Vision and Pattern Recognition. Anchorage, AK: IEEE Computer Society, 2008: 2323-2330

(上接第 280 页)

[10] Li F, Shen C M, Pi L. A new diffusion-based variational model for image denoising and segmentation [J]. J. Math. Imaging Vis., 2006, 26: 115-125

[11] Kim S. PDE-based image restoration; A hybrid model and image denoising[J]. IEEE Trans. on Image Processing, 2006, 15(5): 1163-1170

[12] Fan Qi-bin, Jiao Yu-ling, An overview of image restoration based on variational regularization[J]. Advance in Mathematic, 2012, 41(5): 531-546

[13] Zhu L X, Xia D S. Staircase effect alleviation by coupling gradient fidelity term[J]. Image and Vision Computing, 2008, 28(8): 1163-1170

[14] Rudin L I, Lions P L, Osher S. Multiplicative denoising and de-

blurring: Theory and algorithms[M]// Osher S, Paragios N, eds. Geometric Level Sets in Imaging Vision and Graphics. Berlin; Springer Verlag, 2003

[15] 冯象初, 王卫卫. 图像处理的变分和偏微分方程方法[M]. 北京: 科学出版社, 2009

[16] Weickert J, e Romeny B M, Viergever M A. Efficient and reliable scheme for nonlinear diffusion and filtering[J]. IEEE Trans. on Image Processing, 1998, 7(3): 398-410

[17] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment; from error visibility to structural similarity [J]. IEEE Trans. on Image Processing, 2004, 13(4): 600-612

[18] Evans L C, Garipey R F. Measure theory and fine properties of functions[M]. Boca Raton; CRC Press, 1992