

有监督核化邻域投影分析算法

郑建炜 孔晨辰 王万良 邱虹 章杭科

(浙江工业大学计算机科学与技术学院 杭州 310023)

摘要 通过将鉴别邻域嵌入分析算法扩展到非线性场景,提出了一种有监督核化邻域投影分析算法。该算法在目标函数中引入类别标签和线性投影矩阵,并利用核函数处理非线性数据。通过两种不同策略优化目标函数,可将该算法进一步细分为有监督核化邻域投影分析算法一及有监督核化邻域投影分析算法二。其中,在有监督核化邻域投影分析算法一中应用拉普拉斯搜索方向达到了较快的收敛速度并降低了计算复杂度。实验结果表明,所提算法对于复杂的数据流形具有较高的识别率,且与鉴别邻域嵌入分析等相关算法相比在有效性和鲁棒性方面的表现更为出色。

关键词 弹性嵌入,核方法,投影分析,有监督学习

中图分类号 TP391.4 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.6.062

Kernel-based Supervised Neighborhood Projection Analysis Algorithm

ZHENG Jian-wei KONG Chen-chen WANG Wan-liang QIU Hong ZHANG Hang-ke

(School of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China)

Abstract A new algorithm called KSNPA which exhibits a nonlinear form of discriminative elastic embedding (DEE) was proposed. KSNPA integrates class labels and linear projection matrix into the final objective function, as well as uses kernel function to deal with nonlinear embedding situation. According to two different strategies for optimizing the objective function, the algorithm is divided into kernel-based supervised neighborhood projection analysis algorithm 1 (KSNPA1) and supervised neighborhood projection analysis algorithm 2 (KSNPA2). Furthermore, a deliberately selected search direction, termed as Laplacian Direction, is applied in KSNPA1 for achieving faster convergence rate and lower computational complexit. Experimental results on several databases demonstrate that the proposed algorithm achieves powerful pattern revealing capability for complex manifold data. Moreover, the algorithm is more efficient and robust than DEE and related dimensionality reduction algorithms.

Keywords Elastic embedding, Kernel method, Projection analysis, Supervised learning

1 引言

降维技术^[1]通过将高维数据映射到低维来展现数据的本质结构。在数据挖掘领域中,降维技术具有非常重要的作用:分类、可视化及聚类^[2,3]。目前已有许多降维算法被提出,例如主成分分析方法(Principal Component Analysis, PCA)^[4]、线性 Fisher 判别(Linear Fisher Discriminant, LFD)^[5]、多维标度测量(Multi-Dimensional Scaling, MDS)^[6]等。然而,这些经典线性算法在处理非线性流形数据时无法达到预期效果。为此,研究学者们利用谱方法来解决非线性降维问题,提出相关降维算法:等距映射法(Isometric Mapping, ISOMAP)^[7]、局部线性嵌入(Locally Linear Embedding, LLE)^[8]、拉普拉斯特征映射(Laplacian Eigenmap, LE)^[9]等。这些算法都依赖于样本邻域结构的频谱^[10],通过使用简单的高斯函数达到单峰效果,故无法有效处理边界及不连通流形等问题。

针对上述问题,近年来研究学者们致力于提出新的非线性降维算法,所提随机邻域嵌入分析法(Stochastic Neighbor Embedding, SNE)^[11]及改进的 t 分布 SNE(t-distributed Stochastic Neighbor Embedding, t-SNE)^[12]在已有非线性降维算法的缺陷方面做出了突破。SNE 及 t-SNE 不仅能够同时反映全局和局部数据结构,而且能够处理多流形数据形式^[13,14]。其中 SNE 的核心思想是将高维数据间的欧氏距离转化为概率表达形式来表示近邻样本间的相似度;而 t-SNE 则采用具有对称性的联合概率表达替代 SNE 中的条件概率形式,并在子空间中引入 t 分布表现两两样本间的相似度。然而,只有少数文献关注了 SNE 型算法的非线性本质。Carreira-Perpiñán 结合 SNE 和 LE,提出了一种新的降维算法——邻域嵌入分析法(the Elastic Embedding, EE)^[15],该算法对求解最佳映射的目标函数进行了优化。EE 虽然在算法效率及鲁棒性方面优于 SNE 和 t-SNE,但是由于缺少样本类

到稿日期:2015-03-08 返修日期:2015-05-15 本文受浙江省自然科学基金(LY15F030014),国家自然科学基金(61379123),“十二五”国家科技支撑计划(2012BAD10B01)资助。

郑建炜(1982—),男,博士,副教授,主要研究方向为模式识别、计算机视觉, E-mail: qianzhihe17@163.com;孔晨辰(1988—),男,硕士生,主要研究方向为模式识别;王万良(1957—),男,博士,博士生导师,主要研究方向为智能控制、物联网;邱虹(1989—),女,硕士生,主要研究方向为机器学习、图像处理;章杭科(1988—),男,硕士生,主要研究方向为模式识别。

别标签,因此不适合应用在模式识别中。为了解决这一问题,文本作者曾提出一种鉴别性 EE 分析法(Discriminative EE, DEE),该算法在 EE 的基础上引入了线性投影矩阵^[16]。

由于 DEE 是线性降维算法,它的本质特征使其不能有效解决非线性特征提取问题。故通过在 DEE 的基础上引入核函数,提出一种有监督核化邻域投影分析算法(Kernel Supervised Neighbor Projection Analysis algorithm, KSNPA),将 DEE 扩展到非线性场景。KSNPA 通过输入样本的类别信息构建数据分布的联合概率表达式,用于反映同类和异类数据间的相似度;同时引入线性投影矩阵生成子空间数据;最后通过引入核函数将算法扩展到非线性场景。

本文第 2 节概述了 EE 和 DEE 的算法结构;第 3 节着重阐述了 KSNPA 算法的开发流程;第 4 节通过几个经典数据库验证了所提 KSNPA 的性能;最后对全文进行总结。

2 EE 及 DEE

SNE 及 t-SNE 的目标函数强制保持了子空间与原空间的一致性,这导致算法存在局部最优问题,使得分类性能表现不理想。EE 通过增加一个称为 LE 目标函数的分离点提高了方法的点间距和簇间距,缓解了 SNE、t-SNE 的局部最优问题。给定 N 个 r 维向量 y_1, y_2, \dots, y_N 及其对应的 d 维输入数据 x_1, x_2, \dots, x_N , 其中 $r < d$ 且 y_i 是 x_i 对应的子空间数据。不同于 LE, EE 包含两个权重:一个是有吸引力的权重,称为吸引项 $W^+ = (\omega_{mn}^+)$,另一个是有排斥力的权重,称为排斥项 $W^- = (\omega_{mn}^-)$,且两个权重均为非负矩阵。

为得到最佳映射,EE 通过最小化以下目标函数获取:

$$E(Y) = \sum_{n,m=1}^N \omega_{mn}^+ \|y_n - y_m\|^2 + \lambda \sum_{n,m=1}^N \omega_{mn}^- \exp(-\|y_n - y_m\|^2) \quad (1)$$

其中, λ 是一个手动可调的参数,且 $\omega_{mn}^+ = \exp(-\|x_n - x_m\|^2 / 2\sigma^2)$, $\omega_{mn}^- = \|x_n - x_m\|^2$, $\omega_{nn}^+ = \omega_{nn}^- = 0$, $\forall n$ 。

此外,为使表达方便,定义以下两个辅助变量:

$$\tilde{\omega}_{mn}^- = \omega_{mn}^- \exp(-\|y_n - y_m\|^2) \quad (2)$$

$$\omega_{mn} = \omega_{mn}^+ - \lambda \tilde{\omega}_{mn}^- \quad (3)$$

则可求得 E 针对 y_n 及 Y 的梯度分别为:

$$\frac{\partial E}{\partial y_n} = 4 \sum_{n \neq m} \omega_{nm} (y_n - y_m) \quad (4)$$

$$G(Y; \lambda) = \frac{\partial E}{\partial Y} = 4Y(L^+ - \lambda \tilde{L}^-) = 4YL \quad (5)$$

其中, $L = D - W$, $\tilde{L} = \tilde{D} - \tilde{W}$, L 被称为拉普拉斯矩阵。 W 作为一个已知的矩阵,包含 $\lambda > 0$ 的负权重值。值得注意的是, W_{ij} 是一个对称矩阵,且度量矩阵 $D_{ii} = \sum_j W_{ij}$ 。EE 通过式(5)得到梯度值后,采用固定点迭代法(the Fixed-Point, FP)实现全局快速收敛^[15]。

DEE 属于线性有监督的降维算法,其在 EE 的基础上通过引入类别标签和线性投影矩阵构建目标函数。在上述给定样本中添加类别标签,即 N 个 r 维向量 $y_1^1, y_2^1, \dots, y_{N_1}^1, y_1^2, y_2^2, \dots, y_{N_2}^2, \dots, y_1^c, y_2^c, \dots, y_{N_c}^c$ 及其对应的 d 维有类别标签的样本向量 $x_1^1, x_2^1, \dots, x_{N_1}^1, x_1^2, x_2^2, \dots, x_{N_2}^2, \dots, x_1^c, x_2^c, \dots, x_{N_c}^c$, 其中 $r < d$ 且 y_i^c 是 x_i^c 对应的子空间数据, x_i^c 代表第 c 类的第 i 个样本,样本总类别数为 C , N_i 是第 i 类的样本数,且 $N = N_1 + N_2 + \dots + N_c$ 为总样本数。

引入类别标签后,吸引项和排斥项可分别表示为:

$$\omega_{ij}^+ = \begin{cases} \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right), & \text{if } l_i = l_j \\ 0, & \text{else} \end{cases} \quad (6)$$

$$\omega_{ij}^- = \begin{cases} \|x_i - x_j\|^2, & \text{if } l_i \neq l_j \\ 0, & \text{else} \end{cases} \quad (7)$$

其中, l_i 和 l_j 代表类别标签。此外,引入线性投影矩阵 $A^{r \times d}$, 通过简单的代数运算后式(1)可进一步转化为:

$$\begin{aligned} E(A) &= \sum_{n,m=1}^N \omega_{mn}^+ \|Ax_n - Ax_m\|^2 + \lambda \sum_{n,m=1}^N \omega_{mn}^- \exp(-\|Ax_n - Ax_m\|^2) \\ &= \sum_{n,m=1}^N \omega_{mn}^+ (x_n - x_m)^T A^T A (x_n - x_m) + \lambda \sum_{n,m=1}^N \omega_{mn}^- \exp(-\|x_n - x_m\|^2 A^T A (x_n - x_m)) \end{aligned} \quad (8)$$

EE 及 DEE 均采用共轭梯度法求解目标函数中线性投影矩阵 A 的最优解^[16]。

3 KSNPA

EE、DEE 均为线性降维算法,无法有效处理非线性数据。本节通过引入核函数将 DEE 扩展到非线性场景。给定 $\kappa(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$ 为高维特征空间 F 中两两样本间的内积运算,其中非线性映射函数 $\phi(x) = R^d \rightarrow F$, 即从低维输入空间 R 到高维特征空间 F 的映射。为使表达方便,下文中用 ϕ_i 代替 $\phi(x_i)$ 。

根据非线性映射函数 $\phi(x)$, 特征空间 F 中的线性投影矩阵 A 可以表示为:

$$A = \left[\sum_{i=1}^N b_i^{(1)} \phi_i, \dots, \sum_{i=1}^N b_i^{(d)} \phi_i \right]^T = B\Phi \quad (9)$$

式(9)与核邻域成分分析算法^[17]及核鉴别随机邻域嵌入分析算法(Kernel Discriminative SNE, KDSNE)^[18]中高维特征空间里线性投影矩阵的表述类似。其中 $B = [b^{(1)}, \dots, b^{(r)}]^T \in R^{d \times N}$, $\Phi = [\phi_1, \phi_2, \dots, \phi_N]^T$ 。

通过以上表述,可将 DEE 的吸引项和排斥项从式(6)、式(7)进一步转化为:

$$\begin{aligned} \omega_{ij}^+ &= \begin{cases} \exp\left(\frac{-\|\phi_i - \phi_j\|^2}{2\sigma^2}\right), & \text{if } l_i = l_j \\ 0, & \text{else} \end{cases} \\ &= \begin{cases} \exp\left(\frac{1 - \kappa_{ij}}{2\sigma^2}\right), & \text{if } l_i = l_j \\ 0, & \text{else} \end{cases} \\ \omega_{ij}^- &= \begin{cases} \|\phi_i - \phi_j\|^2, & \text{if } l_i \neq l_j \\ 0, & \text{else} \end{cases} \\ &= \begin{cases} 2 - 2\kappa_{ij}, & \text{if } l_i \neq l_j \\ 0, & \text{else} \end{cases} \end{aligned} \quad (10) \quad (11)$$

依据式(9)一式(11),可得出特征空间 F 中 DEE 的目标函数:

$$\begin{aligned} \sum_{n,m=1}^N \omega_{mn}^+ \|B\Phi\phi_n - B\Phi\phi_m\|^2 + \lambda \sum_{n,m=1}^N \omega_{mn}^- \exp(-\|B\Phi\phi_n - B\Phi\phi_m\|^2) &= \sum_{n,m=1}^N \omega_{mn}^+ (k_n - k_m)^T B^T B (k_n - k_m) + \\ &\lambda \sum_{n,m=1}^N \omega_{mn}^- \exp(-\|k_n - k_m\|^2 B^T B (k_n - k_m)) \end{aligned} \quad (12)$$

其中, $k_n = [\kappa(x_1, x_j), \dots, \kappa(x_N, x_j)]^T$ 是列向量。由上式可知, DEE 的目标函数可通过核函数、矩阵 B 计算得到。故高维特征空间中 DEE 的目标是得到矩阵 B 的最优解。文中采用高斯核函数 $k(x, y) = \exp(-\|x - y\|^2 / \sigma)$, σ 取为相应样本矩阵 X 中训练样本集的方差参数。

采用两种策略构建 KSNPA 的目标函数。KSNPA1 利用矩阵 \mathbf{B} 参数化目标函数,通过引入核函数可将目标函数 $E(\mathbf{B})$ 的梯度表示为:

$$\begin{aligned} \frac{\partial E(\mathbf{B})}{\partial \mathbf{B}} &= 2\mathbf{B} \sum_{n,m=1}^N (\omega_{nm}^+ - \lambda\omega_{nm}^-) \exp(-(k_n - k_m)^T \mathbf{B}^T \mathbf{B} (k_n - k_m)) (k_n - k_m) (k_n - k_m)^T \\ &= 2\mathbf{B} \sum_{n,m=1}^N \omega_{nm} (k_n - k_m) (k_n - k_m)^T \\ &= 4\mathbf{BK}(\mathbf{D}^+ - \mathbf{W}^+ - \lambda\mathbf{D}^- + \lambda\mathbf{W}^-) \mathbf{K}^T \\ &= 4\mathbf{BK}(\mathbf{L}^+ - \lambda\mathbf{L}^-) \mathbf{K}^T \\ &= 4\mathbf{BK}\mathbf{L}\mathbf{K}^T \end{aligned} \quad (13)$$

其中, $\omega_{nm} = \omega_{nm}^+ - \lambda\omega_{nm}^- \exp(-(k_n - k_m)^T \mathbf{B}^T \mathbf{B} (k_n - k_m))$ 。

KSNPA2 利用线性投影矩阵 \mathbf{A} 参数化高维特征空间的目标函数,则可将式(12)进一步转化为:

$$\begin{aligned} \frac{\partial E(\mathbf{A})}{\partial \mathbf{A}} &= 2\mathbf{B}\Phi \sum_{n,m=1}^N \omega_{nm} (\phi_n - \phi_m) (\phi_n - \phi_m)^T \\ &= 2 \sum_{n,m=1}^N \omega_{nm} \mathbf{B} (k_n - k_m) (\phi_n - \phi_m)^T \\ &= 2\mathbf{B} \sum_{n,m=1}^N \omega_{nm} \mathbf{Q}_{nm}^{(k_n - k_m)} \Phi \end{aligned} \quad (14)$$

其中, $\mathbf{Q}_{nm}^{(k_n - k_m)}$ 为 $n \times m$ 矩阵,矩阵的第 n 列由向量 $k_n - k_m$ 组成,第 m 列由向量 $k_m - k_n$ 组成,其余列由零向量组成。

许多基于梯度的优化方法如梯度下降法、共轭梯度下降法等可用于优化式(13)及式(14)中的矩阵 \mathbf{B} 。由于 Φ 是一个常数矩阵,则从式(14)可知最优化线性投影矩阵 \mathbf{A} 就意味着只需最优化矩阵 \mathbf{B} 即可。其次,根据 $\mathbf{A} = \mathbf{B}\Phi$ 及式(10)、式(11)可知欧氏距离的值只受 \mathbf{B} 、 k_n 和 k_m 的影响,故无须计算 Φ 的值。

在梯度优化过程中,KSNPA1 和 KSNPA2 每一次迭代的算法复杂性均为 $O(N^2)$ 。但是,KSNPA2 的目标函数呈现不对称性,不适合通过最佳搜索方向快速收敛目标函数的梯度表达式,故在 KSNPA1 上应用搜索方向最优化梯度。

采用固定点迭代策略^[19]将对称正定矩阵 \mathbf{D}^+ 从 $\partial E/\partial \mathbf{B}$ 中分离出来:

$$\frac{\partial E}{\partial \mathbf{B}} = 4\mathbf{BK}(\mathbf{D}^+ + \mathbf{L} - \mathbf{D}^+) \mathbf{K}^T = 0 \quad (15)$$

上式可得固定点的搜索方向 $\Delta_{\text{SP}} = \mathbf{BK}(\mathbf{D}^+ - \mathbf{L}) \mathbf{K}^T (\mathbf{KD}^+ \mathbf{K}^T)^{-1} - \mathbf{B}$,且梯度下降时的定点方向为 $\mathbf{B} \leftarrow \mathbf{B} + \alpha \Delta_{\text{SP}}$,并满足沃尔夫条件 $\alpha > 0$ 。下文中,该算法被称为 KSNPA1_SP。

此外,依据数值优化理论^[19],该线性搜索方法可进一步表示为:

$$\begin{aligned} \mathbf{B}_{k+1} &= \mathbf{B}_k + \alpha_k \Delta_k \\ \mathbf{H}_k \Delta_k &= -\mathbf{g}_k \end{aligned} \quad (16)$$

其中, Δ_k 是选择的搜索方向, \mathbf{g}_k 为目标函数, \mathbf{H}_k 为正定矩阵以确保下降方向,并且满足沃尔夫条件 $\Delta_k^T \mathbf{g}_k < 0$ 。

当 \mathbf{H}_k 选取单位矩阵 \mathbf{I} 时,等价于梯度下降方法,但其收敛速度较慢;当 \mathbf{H}_k 选取 Hessian 矩阵时,等价于牛顿方法,但其迭代次数过多。为了快速收敛并降低计算复杂度,本文的思想是尽可能确保 Hessian 矩阵的恒定及正定性,故 KSNPA1 的 Hessian 矩阵可表示为:

$$\begin{aligned} \frac{\partial^2 E}{\partial \mathbf{B}^2} &= 4(\mathbf{KL}^+ \mathbf{K}^T) \otimes \mathbf{I}_d - 4\lambda(\mathbf{KL}^- \mathbf{K}^T) \otimes \mathbf{I}_d - \\ &4\lambda(\mathbf{I}_N \otimes \mathbf{B}) \frac{\partial \mathbf{KL}^- \mathbf{K}^T}{\partial \mathbf{B}} \end{aligned} \quad (17)$$

由上式可知,式中只有 \mathbf{L}^+ 部分是常数且为对称半正定。

依据该性质,选取其为搜索方向,称该搜索方向为拉普拉斯方向(Laplacian Direction, LD)。在实际应用中,为得到 LD 的方向 Δ_k 并提高计算效率,采用 $\mathbf{R}^T (\mathbf{R}\Delta_k) = -\mathbf{g}_k$ 替代 $\mathbf{H}_k \Delta_k = -\mathbf{g}_k$,其中 \mathbf{R} 是 \mathbf{H}_k 的乔尔斯基分解。

4 实验分析

分别采用 USPS 手写数字数据库 (<http://www-i6.informatik.rwth-aachen.de/keysers/usps.html>)、哥伦比亚大学图像数据库 (COIL-20) (<http://www1.cs.columbia.edu/CAVE/software/softlib/coil-20.php>)、ORL 人脸数据库 (<http://www.cam-orl.co.uk>) 验证所提 KSNPA1_SP、KSNPA2 方法在不同应用领域的性能,包括分簇及识别能力。所有实验均在一台 Intel Core2 CPU 1.8GHz 的 PC 机上进行,操作系统为 Windows XP,算法采用 Matlab7.1 实现。

4.1 分簇性能

USPS 手写数字数据库包含 10 个数字字符,总共 1100 个样本,样本分辨率为 16×16 像素。实验中,每类数字随机选取 60 个样本作为输入数据。图 1 是 USPS 数据库的部分样例。




图 1 USPS 数据库的部分样例

如第 3 节所述,为了最优化 KSNPA1,实验采用固定点搜索方向法(KSNPA1_SP)和拉普拉斯搜索方向法(KSNPA1_LD)。此外,为了展示 KSNPA1 和 KSNPA2 的分簇性能,本节将所提算法与其它相关监督算法包括 DEE 和 KDSNE 进行比较。具体参数配置如下:最终收敛条件为 $1e^{-3}$,最大迭代次数为 1000,其余参数设置与文献^[15]一致。

图 2 为 USPS 的分簇可视化结果,COIL-20 和 ORL 的分簇可视化结果与 USPS 基本一致,本小节以 USPS 为例,对 COIL-20 和 ORL 的结果不做讨论。图 2 中不同颜色的点代表了不同的类别。从图中可见,KSNPA1 和 KSNPA2 比 DEE 和 KDSNE 具有更强的分簇性能,DEE 存在明显的异类样本间混叠。KDSNE 不仅存在明显的类间重叠,而且类内聚类效果较差,这是由于共轭梯度法的次优化所致,加上算法中众多参数需手动设置调整,难以配置到最优状态。在聚类可视化方面对比 KSNPA1 和 KSNPA2,可得出 KSNPA1 比 KSNPA2 更为出色的结论,KSNPA2 类间重叠较多,且各类簇的分布状态起伏比较混杂。彩色坐标进一步显示,KSNPA1_LD 比 KSNPA1_SP 能更准确地分离不同类中存在的底层结构。




图 2 USPS 数据库分簇可视化

此外,实验过程中通过比较上述 5 种算法在不同迭代次

数下的目标函数值来说明算法在高维特征空间中体现出不同收敛能力。图3为USPS数据库中不同迭代次数下的目标函数值,各算法均在一定迭代次数下达到目标函数的收敛值。从图3中可见,KSNPA1_LD比其它算法更具竞争力,KSNPA1_LD用最少的迭代次数达到了最佳目标函数值,而KDSNE却需要最多的迭代次数才能满足收敛条件。此外,KSNPA1_LD比KSNPA1_SP、KSNPA2更高效,KSNPA1_LD仅需80次迭代就可获得最佳目标函数值,而对于相同的收敛条件,KSNPA1_SP却需要大约120次迭代才能完成,KSNPA2甚至需要大约270次迭代才能完成。因此,后续实验采用KSNPA1_LD作为对比算法模型。




图3 USPS数据库中不同迭代次数下的目标函数值

4.2 鉴别性能

采用COIL-20、ORL、USPS数据库对所提算法的鉴别性能进行评估。

COIL-20数据库包含20个外形差异较大的物体。每个物体有72张不同视角、分辨率为 128×128 像素的256级灰度图像。该数据库的生成是将物体置于一个旋转台面,每隔 5° 拍摄一个视角的图像,得到每个物体72个不同视角的姿态图。图4是COIL-20数据库的部分样例。



图4 COIL-20数据库的部分样例

ORL人脸数据库包括40人共400张人脸灰度图像。每人10张图像中包括了姿态、表情和光照的变化。每张图像的分辨率为 112×92 像素。图5是ORL人脸库的部分人脸样例。



图5 ORL人脸库的部分人脸样例

由于类别标签是提高鉴别性能的有效方法,因此本节将KSNPA1和KSNPA2与有监督的降维算法DEE和KDSNE进行比较。实验步骤设计如下:首先,将样本集随机分为训练样本集 X_{train} 和测试样本集 X_{test} ;其次,选取每个对象的 l 个样本进行模型训练;然后,将所有的训练样本以及测试样本投影至低维子空间;最后,采用最近邻分类器进行识别率检测。各方法的实验配置参数同4.1节一致。

图6示出3个数据库中,不同子空间维数下DEE、KDSNE、KSNPA1和KSNPA2的识别率。其中3个数据库COIL-20、ORL和USPS的训练样本大小分别为每类10个样本、5个样本和14个样本。由图6可知,KSNPA1和KSNPA2相较其他算法在鉴别性能的表现上更强,这表明

KSNPA1和KSNPA2充分抓住了数据特征的本质表现。此外,KSNPA1和KSNPA2的最佳识别率非常接近,而KDSNE的最佳识别率在4个算法中最低。




图6 4种方法在不同数据库中的识别率和对应维数比较

图7分析了不同数据库中不同子空间维数下的运行时间。由图可知,不同子空间维数下,KSNPA1需最少的运行时间,KSNPA2的运行时间多于KSNPA1,而KDSNE所需运行时间最多。以上结果证明,采用拉普拉斯搜索方向的KSNPA1是获得最优投影矩阵的最佳算法。

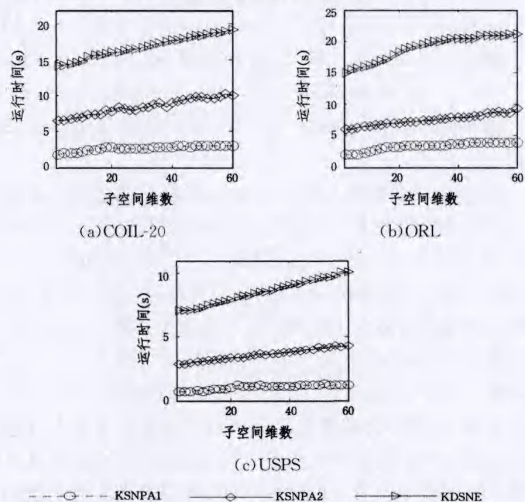


图7 不同数据库中不同子空间维数下的运行时间分析

结束语 本文提出一种新的被称为有监督核化邻域投影分析算法的降维算法,该算法通过引入核函数将DEE扩展到非线性场景,使其能够处理非线性数据。根据两种不同的策略来优化目标函数,将有监督核化邻域投影分析算法分为KSNPA1和KSNPA2。理论分析证明,有监督核化邻域投影分析算法模型具有两个优点:1)利用核方法解决非线性应用,通过引入线性投影矩阵有效避免样本外问题;2)获得最优投影矩阵所需的迭代次数少于其它SNE类型算法,显著减少了算法的计算量。在USPS、COIL-20和ORL这3个数据库上得到的实验结果表明,KSNPA1要比KSNPA2、DEE和其他相关降维算法更加实用。然而,梯度计算过程中的二次成本

(下转第324页)

一。现有的研究大都设定一些启发式规则用于图片的合成过程,本文提出了一种基于贝叶斯方法的图片合成模型。在给定理想的图片合成模型后,对传感器误差和图片误差进行了分析。由于图片误差和几何误差之间是相关的,进而分析了它们之间的关系。在根据已有数据对模型进行后验估计时,通过最小化能量来得到模型的先验参数。在目标函数的优化过程中,基于现有研究,通过重新赋权值的迭代方法进行优化问题的求解。实验表明,提出的图片合成模型与相关方法相比具有更好的图片合成以及渲染效果。

参考文献

- [1] Kang S B, Li Y, Tong X, et al. Image-based rendering[J]. Foundations and Trends® in Computer Graphics and Vision, 2012, 2(3): 173-258
- [2] Dai Zhi-hua, Xu Yu-ping, Bu Jing, et al. Light Field Microscope to Achieve Three-Dimensional Real-Time Naked-Eye Display[J]. ACTA OPTICA SINICA, 2012, 32(10): 232-235 (in Chinese)
戴志华, 徐于萍, 步敬, 等. 光场显微镜实现裸眼三维实时显示[J]. 光学学报, 2012, 32(10): 232-235
- [3] Liu Yong-chun, Gong Hua-jun, Shen Chun-ling, et al. Research of Lightfield Acquisition and Reconstruction Based on Mask[J]. ACTA OPTICA SINICA, 2014(8): 105-110 (in Chinese)
刘永春, 龚华军, 沈春林. 基于掩膜的光场采集与重建的研究[J]. 光学学报, 2014(8): 105-110
- [4] Buehler C, Bosse M, McMillan L, et al. Unstructured lumigraph rendering[C]//Proceedings of the 28th Annual Conference on Computer Graphics and Interactive Techniques. ACM, 2011: 425-432
- [5] Wanner S, Goldluecke B. Spatial and angular variational super-resolution of 4D light fields [M] // Computer Vision-ECCV

(上接第 315 页)

仍是算法上的瓶颈,后续工作将主要针对上述问题展开,并探索进行增量式 DEE 的研究,以适应一些在线应用领域。

参考文献

- [1] Huang Jin-jie, Lv Ning, Li Shuang-quan, et al. Feature selection for classificatory analysis based on information-theoretic criteria[J]. Acta Automatica Sinica, 2008, 34(3): 383-392
- [2] Venna J, Pectone J, Nybo K, et al. Information retrieval perspective to nonlinear dimensionality reduction for data visualization[J]. Journal of Machine Learning Research, 2010, 11(1): 451-490
- [3] Yang W Y, Liang W, Xin L, et al. Subspace semi-supervised fisher discriminant analysis[J]. Acta Automatica Sinica, 2009, 35(12): 1513-1519
- [4] Alfaro C A, Aydin B, Valencia C E, et al. Dimension reduction in principal component analysis for trees[J]. Computational Statistics & Data Analysis, 2014, 74: 157-179
- [5] Yang W, Wu H. Regularized complete linear discriminant analysis[J]. Neurocomputing, 2014, 137: 185-191
- [6] Machado J T. Multidimensional scaling analysis of fractional systems[J]. Computers & Mathematics with Applications, 2012, 64(10): 2966-2972
- [7] Tenenbaum J, Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290: 2319-2323
- [8] Roweis S T, Lawrence K S. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290: 2323-2326
- [9] Yin X S, Chen S C, Hu E L. Regularized soft K-means for dis-

2012. Springer Berlin Heidelberg, 2012: 608-621

- [6] Baker S, Kanade T. Limits on super-resolution and how to break them[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 24(9): 1167-1183
- [7] Shan Q, Jia J, Agarwala A. High-quality motion deblurring from a single image[J]. ACM Transactions on Graphics (TOG), ACM, 2008, 27(3): 73-82
- [8] Roth S, Black M J. Fields of experts: A framework for learning image priors[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005 (CVPR 2005). IEEE, 2005, 2: 860-867
- [9] Chambolle A. An algorithm for total variation minimization and applications[J]. Journal of Mathematical Imaging and Vision, 2014, 20(1/2): 89-97
- [10] Cho T S, Zitnick C L, Joshi N, et al. Image restoration by matching gradient distributions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(4): 683-694
- [11] Beck A, Teboulle M. A fast iterative shrinkage-thresholding algorithm for linear inverse problems[J]. SIAM Journal on Imaging Sciences, 2009, 2(1): 183-202
- [12] Wanner S, Meister S, Goldlücke B. Datasets and benchmarks for densely sampled 4D light fields[C]//Annual Workshop on Vision, Modeling and Visualization: VMV. 2013: 225-226
- [13] Vaish V, Adams A. The (New) Stanford Light Field Archive [OL]. <http://lightfield.stanford.edu>
- [14] Lin Xiao-ping, Zhou Shi-lin, Zhang Guan-liang, et al. An Image Mosaic Technology Based on Ant Colony Algorithm and Mutual Information Measure[J]. Journal of Chongqing University of Technology (Natural Science), 2013, 27(1): 76-81 (in Chinese)
林小平, 周石琳, 张官亮, 等. 一种基于蚁群算法和互信息测度的图像拼接技术[J]. 重庆理工大学学报(自然科学), 2013, 27(1): 76-81

criminant analysis[J]. Neurocomputing, 2013, 103(1): 29-42

- [10] Maras K L, et al. Mental imagery scanning in autism spectrum disorder[J]. Research in Autism Spectrum Disorders, 2014, 8(10): 1416-1423
- [11] Hinton G, Roweis S T. Stochastic neighbor embedding[M]//Advances in Neural Information Processing Systems 15. MIT Press, 2003: 833-840
- [12] Maaten L, Hinton G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(11): 2579-2605
- [13] Lunga D, Ersoy O. Spherical stochastic neighbor embedding of hyperspectral data[J]. IEEE Transactions on Geoscience and remote sensing, 2013, 51(2): 857-871
- [14] Lee J A, Verleysen M. Shift-invariant similarities circumvent distance concentration in stochastic neighbor embedding and variants[J]. Procedia Computer Science, 2011, 4: 538-547
- [15] Carreira-Perpiñan M A. The elastic embedding algorithm for dimensionality reduction[C]//27th International Conference on Machine Learning. 2010: 167-174
- [16] Zheng J W, Zhang H K, Cattani C, et al. Dimensionality reduction by supervised neighbor embedding using laplacian search[J]. Computational and Mathematical Methods in Medicine, 2014: 2014(1): 594379
- [17] Yang W, Wang K Q, Zuo W M. Fast neighborhood component analysis[J]. Neurocomputing, 2012, 83: 31-37
- [18] Zheng J W, et al. Fast Discriminative Stochastic Neighbor Embedding Analysis[J]. Computational and Mathematical Methods in Medicine, 2013, 2013(11): 367-371
- [19] Nocedal J, Wright S. Numerical Optimization (Second edition) [M]. Springer-Verlag, 2006