

中图分类号: TP391.4 文献标志码: A 文章编号: 1006-8961(2011)12-2152-07

论文索引信息: 何光辉, 张太平, 唐远炎. 非监督子空间学习中关联度量多维尺度分析[J]. 中国图象图形学报, 2011, 16(12): 2152-2158

非监督子空间学习中关联度量 多维尺度分析

何光辉¹⁾, 张太平²⁾, 唐远炎²⁾

¹⁾(重庆大学数学与统计学院, 重庆 401331) ²⁾(重庆大学计算机学院, 重庆 400044)

摘要: 多维尺度分析已经在维度约减和数据挖掘领域得到了广泛应用。MDS的主要缺点是其定义在训练数据上,对于新的测试样本无法直接获得映射结果。另外,MDS基于欧氏距离度量,不适合获取相似数据中的非线性流形结构。将MDS扩展到关联度量空间,称为关联度量多维尺度分析(CMDS)。与传统MDS在训练数据中完成映射,进而缩小空间范围相比,CMDS能够直接获得测试样本映射结果。此外,CMDS基于关联度量,能够有效学习相似数据中的非线性流形结构。理论分析表明,CMDS可以利用核方法扩展到新特征空间,解决非线性问题。实验结果表明,CMDS及其核形式KG-CMDS性能优于常用传统降维方法。

关键词: 非监督子空间;关联度量;多维尺度分析

Correlation-based multidimensional scaling for unsupervised subspace learning

He Guanghui¹⁾, Zhang Taiping²⁾, Tang Yuanyan²⁾

¹⁾(College of Mathematics and Statistics, Chongqing University, Chongqing 401331 China)

²⁾(College Computer Science, Chongqing University, Chongqing 400044 China)

Abstract: Multidimensional scaling (MDS) has been applied in many applications such as dimensionality reduction and data mining. However, one of the drawbacks of MDS is that it is only defined on "training" data with no clear extension to out-of-sample points. Furthermore, since MDS is based on Euclidean distance, it is not suitable for detecting the nonlinear manifold structure embedded in the similarities between data points. In this paper, we extend MDS to the correlation measure space (CMDS). In contrast with MDS where the mapping between the input and reduced spaces is implicit, CMDS employs an explicit nonlinear mapping between the both. As a result, CMDS can directly provide predictions for new samples. Correlation is a similarity measure, so the CMDS method can effectively capture the nonlinear manifold structure of data embedded in the similarities between the data points. Theoretical analysis also shows that CMDS has some properties similar to kernel methods and can be extended to the feature space. The effectiveness of our approach is demonstrated by extensive experiments on various data sets, in comparison with existing dimensionality reduction algorithms.

Keywords: unsupervised subspace learning; correlation measure; multidimensional scaling

收稿日期: 2010-09-25; 修回日期: 2010-12-11

基金项目: 国家自然科学基金项目(1010200720100098)。

第一作者简介: 何光辉(1976—), 男, 讲师。2010年于重庆大学获计算机应用与技术专业博士学位, 主要研究方向模式识别、数据挖掘。E-mail: ghhe@cqu.edu.cn。

0 引言

非监督子空间学习是机器学习和数据挖掘中一个重要的预处理过程。子空间学习的目标是寻找嵌入在原始高维数据中的低维流形,然后利用获得的低维数据描述作为模式特征进行识别和分类。因此,子空间学习还可以视为一种保留区分性较大特征剔除区分度较小特征的特征提取方法。传统的非监督子空间学习方法大致可以分为两类。一类是嵌入类方法,如多尺度分析^[1]、局部线性嵌入(LLE)^[2]和拉普拉斯特征映射(LE)^[3];另一类投影类方法,如主成分分析(PCA)^[4]和局部保留投影(LPP)^[5],两类方法的不同之处在于,嵌入类方法的映射是隐式的,而投影类方法的映射是可见的。在模式识别应用中,映射的可见性十分重要,因为通过映射,可以对新样本进行预测。

经典的多维尺度分析是一种典型的嵌入式子空间学习方法。它的映射目标是保留样本点对间的距离关系,这种关系由样本间相异性,欧氏距离描述。多维尺度分析已广泛应用于数据描述和数据挖掘中。多维尺度分析的主要缺点是它定义在训练数据集上,不能扩展到样本集外测试数据。所以多维尺度分析不能直接提供新样本的映射结果。此外多维尺度分析不适合处理大规模数据集。在大规模数据集中,往往期望从少量数据中学习其内部映射,然后推广到其他数据。

进一步,由文献[6-7]可知,在高维数据空间中存在低维的非线性流形结构,这种内在的几何结构往往嵌入在相似性数据中^[8]。多维尺度分析使用欧氏距离作为度量标准,而欧氏距离是获得数据间相异性的度量标准,所以多维尺度分析获得的是相异性而不是相似性。从而多维尺度分析不适合检测嵌入在相似性中的流形结构。为解决这一难题,近年来许多学者提出多维尺度分析的扩展算法^[9-10]。一个重要的扩展算法是等距映射(ISOMAP)方法^[10],该方法在流形中用近似测地距离取代欧氏距离。测地距离可以看做邻域图上的欧氏距离,所以它并没有改变欧氏距离得到的数据点间相异性的本质。另外,与多维尺度分析类似,其他的嵌入式方法^[2-3,9-10],具有的共同缺点是不能直接完成异常数据(out-of-sample)的映射问题。

与基于嵌入的方法不同,PCA是一种基于协方

差结构分析的投影类数据降维方法,数据被投影到方差变化最大的方向。然而PCA与MDS相似,两者都是通过最小化高维点对间欧氏距离和它们低维对应点对的平方差来获得数据的低维描述。PCA同样不能有效获取嵌入在相似性数据点中的流形结构。为了克服使用欧氏距离带来的缺陷,LPP算法使用点对间的加权距离取代欧氏距离,两点间距离越小,权重越大。这种方法描述的是数据点间的相似性,而非相异性。但由于距离权重通常由ad hoc方式获得,效果往往不能得到保证。关联度量是一种更好的描述数据间相似性的度量方法,已经在机器学习和模式识别^[11]等领域取得广泛应用^[12-14]。

提出一种结合相似性关联度量和多维尺度分析的子空间学习方法,称为CMDS。与传统MDS相比,CMDS可以直接计算新增数据的映射结果,而不需要重新建立模型。同时,能够更好获取嵌入在相似数据点间的非线性流形结构。理论分析表明,CMDS可以通过核函数扩展应用于解决非线性问题。实验表明,CMDS及其核形式效果优于现有降维算法。

1 相关研究

定义 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ 为 n 个 p 维欧氏空间 R^p ($p > n$)中的数据点。其中点间距离,即相异性通过欧氏距离获得,定义为 $\mathbf{D} = \{d_{ij}^2\}$,其中 $d_{ij}^2 = (\mathbf{x}_i - \mathbf{x}_j)^T(\mathbf{x}_i - \mathbf{x}_j)$ 。多维尺度分析MDS通过最小化高维数据点对和低维数据点对间的误差平方和来获得低维嵌入映射。其低维映射结果记为 $\mathbf{Y} = [y_1, y_2, \dots, y_n]^T$ 。在多维尺度分析中使用的损失函数为

$$E = \sum_{ij} (d_{ij} - d'_{ij})^2 \quad (1)$$

式中, $d'_{ij} = (\mathbf{y}_i - \mathbf{y}_j)^T(\mathbf{y}_i - \mathbf{y}_j)$ 为低维数据 y_i 和 y_j 间的欧氏距离。通过最小化损失函数式(1),原始输入数据 \mathbf{X} 的低维数据表示 \mathbf{Y} 即可通过以下步骤获得。

定义 \mathbf{B} 为一个内积矩阵

$$[\mathbf{B}]_{ij} = b_{ij} = \mathbf{y}_i^T \mathbf{y}_j \quad (2)$$

利用已知的平方距离 $\{d_{ij}\}$,矩阵 \mathbf{B} 可以利用式(1)计算得

$$\mathbf{B} = -\frac{1}{2} \left(\mathbf{I} - \frac{1}{n} \mathbf{e} \mathbf{e}^T \right) \mathbf{D} \left(\mathbf{I} - \frac{1}{n} \mathbf{e} \mathbf{e}^T \right) \quad (3)$$

式中, \mathbf{I} 是 $n \times n$ 的正定矩阵, $\mathbf{e} = [1 \ 1 \ \dots \ 1]^T$ 。

根据矩阵的对称半正定性, \mathbf{B} 可以做矩阵分解, $\mathbf{B} = \mathbf{V}\mathbf{A}\mathbf{V}^T$ 。其中 $\mathbf{A} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ 是对角阵, $\mathbf{V} = [v_1 \ v_2 \ \dots \ v_n]$ 为正交矩阵。 $\lambda_1, \lambda_2, \dots, \lambda_n$ 和 v_1, v_2, \dots, v_n 分别为矩阵 \mathbf{B} 的特征值和对应的特征向量。不失一般性, 假设 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ 。在实际应用中, 可以通过选择前 k ($k \leq n$) 个较大的特征值及其特征向量构造原始数据集 \mathbf{X} 的 k 维描述。

由以上过程可知, 多维尺度分析定义在训练数据集上, 不能直接完成对新样本的映射。由损失函数式(1)可以看出, 多维尺度分析保留了距离分布较远点间的距离(相异性), 而不是分布较近点间的距离(相似性)。因此, MDS 不适合处理存在低维非线性流形结构的高维数据降维问题。以下结合关联相似性度量解决以上问题。

2 基于关联度量的多维尺度分析

关联度量是一种具有尺度不变性的对称度量准则。通常通过计算两个向量的相似性获得。向量 \mathbf{u} 与 \mathbf{v} 间的关联度量定义如下

$$\text{Corr}(\mathbf{u}, \mathbf{v}) = \frac{\mathbf{u}^T \mathbf{v}}{\sqrt{\mathbf{u}^T \mathbf{u}} \sqrt{\mathbf{v}^T \mathbf{v}}} = \left\langle \frac{\mathbf{u}}{\|\mathbf{u}\|}, \frac{\mathbf{v}}{\|\mathbf{v}\|} \right\rangle \quad (4)$$

式中, $\langle \cdot, \cdot \rangle$ 代表两个向量的内积运算。它对应两个向量的夹角 θ , 使得 $\cos \theta = \text{Corr}(\mathbf{u}, \mathbf{v})$ 。两向量的关联度量值越大, 表示它们关系越紧密。由式(4)可知, 关联度量等价于两个向量分别归一化后进行内积运算。由于关联度量可以代表数据点间的相似性, 所以下面将其引入 MDS 中。

2.1 CMDS

同样假设数据集 $\mathbf{X} = [x_1 \ x_2 \ \dots \ x_n]^T$ 为 n 个 p 维欧氏空间 R^p ($p > n$) 中的数据点。令 $\bar{\mathbf{D}} = \{d_{ij}\}$ 表示基于关联度量的样本点对间的相似性, 其中 $d_{ij} = \frac{\mathbf{x}_i^T \mathbf{x}_j}{\sqrt{\mathbf{x}_i^T \mathbf{x}_i \mathbf{x}_j^T \mathbf{x}_j}}$ 表示数据点 \mathbf{x}_i 与 \mathbf{x}_j 间的关联度量。本文中利用中心关联度量计算数据点对间相似性。由式(2)(4)可推广得, $\mathbf{B} = \bar{\mathbf{D}}$, 该式表明, 基于 MDS 的关联度量由两个向量之间的内积决定。由于矩阵 \mathbf{B} 的对称和半正定性, 类似于传统 MDS, 可以通过计算特征值问题获得数据的低维表述 \mathbf{Y} , 见下式

$$\mathbf{B}\mathbf{v} = \lambda\mathbf{v} \quad (5)$$

由此可得 $\mathbf{Y} = \mathbf{V}_k \mathbf{A}_k^{\frac{1}{2}}$, 其中只利用了前 k 个较大特征值对应的特征向量。

正如前文所述, 传统的多维尺度分析方法基于欧氏距离度量, 保留了距离较大的数据点间的相似性。与之不同, CMDS 通过使用关联度量, 保留了相似数据点间的关联结构。由于内在流形结构往往嵌入在相似数据点间, 所以 CMDS 比传统 MDS 能够更好地获得数据中的非线性流形结构。

2.2 CMDS 与核 PCA 的联系

传统 MDS 与 PCA 之间存在紧密联系, 但是我们发现核 PCA 方法与 CMDS 之间也存在着紧密的联系。下面具体分析 CMDS 与核 PCA 之间的联系。

在核方法中, 通过一个非线性映射 $\Phi(\cdot)$ 将输入数据映射到特征空间, 然后在特征空间完成特征提取。核方法的优点是, 通常并不需要知道非线性映射 $\Phi(\cdot)$ 的具体形式, 而只需选择适合的核函数, 即计算出映射后数据样本间的内积 $\Phi(\cdot)^T \Phi(\cdot)$ 。选择适合的核函数可以将原始空间的非线性问题转化为特征空间中的线性可分问题。通过核方法提取特征检测原始空间中的非线性结构已经成为近年来的研究热点^[15-16]。为简单起见, 以下假设初始样本数据集 \mathbf{X} 为零均值。

在核 PCA 中, 首先利用一个非线性映射将数据集 \mathbf{X} 映射到特征空间; 然后在特征空间中计算协方差矩阵及其特征值特征向量; 最后, 通过求解以下特征值问题获得数据低维描述

$$\mathbf{K}\mathbf{a} = \lambda\mathbf{a} \quad (6)$$

式中, \mathbf{K} ($K_{ij} = k(x_i, x_j)$) 是一个核矩阵。由文献[17-18]可知, 正规化核映射效果优于一般核函数映射。根据文献[17-18], 正规化核函数可定义如下

$$\{K_s\}_{ij} = k_s(x_i, x_j) = \left\langle \frac{\Phi(x_i)}{\|\Phi(x_i)\|}, \frac{\Phi(x_j)}{\|\Phi(x_j)\|} \right\rangle = \frac{k(x_i, x_j)}{\sqrt{k(x_i, x_i)k(x_j, x_j)}} \quad (7)$$

注意到点对之间的线性核函数即内积运算可以表示为

$$K_{ij} = k_s(x_i, x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle = \mathbf{x}_i^T \mathbf{x}_j \quad (8)$$

对核 PCA 线性正规化, 由式(7)(8)得

$$\{K_s\}_{ij} = \frac{\mathbf{x}_i^T \mathbf{x}_j}{\sqrt{\mathbf{x}_i^T \mathbf{x}_i \mathbf{x}_j^T \mathbf{x}_j}} \quad (9)$$

根据相关度量式(4)的定义可以知道, 式(9)中 $\{K_s\}_{ij}$ 等价于样本 \mathbf{x}_i 与 \mathbf{x}_j 的相关性度量。即核矩阵 \mathbf{K} 等价于 CMDS 中的点对相关矩阵 $\bar{\mathbf{D}}$ 。所以, CMDS

等价于在核 PCA 中,使用正规化线性核函数的情形。由下文实验结果可以看出,在使用其他非正规化核函数时,CMDS 效果优于核 PCA。

2.3 测试样本

从上面的讨论可以看出,CMDS 与核 PCA 方法联系紧密。核 PCA 通过核函数,将输入数据映射到特征空间。因此,CMDS 也可以通过正规化线性核函数将数据映射到低维空间,而不需要知道映射的具体形式,从而有

$$\begin{aligned} \rho: R^p &\rightarrow R^k \\ X \mapsto \rho(X) &= V_k \Lambda_k^{-\frac{1}{2}} \left\langle \frac{X}{\|X\|}, \frac{X}{\|X\|} \right\rangle V_k \Lambda_k^{-\frac{1}{2}} \end{aligned} \quad (10)$$

式中, R^p 代表原始空间, R^k ($k < p$) 代表降维后空间, Λ_k 为对角矩阵,对角线元素为相似矩阵 \bar{D} 的前 k 个特征值。 V_k 是由特征值对应特征向量组成的矩阵。在 CMDS 中,新样本的映射可以由变换 ρ 直接完成

$$\begin{aligned} \rho: X_{\text{new}} &\mapsto \rho(X_{\text{new}}) = \left\langle \frac{X_{\text{new}}}{\|X_{\text{new}}\|}, \frac{X}{\|X\|} \right\rangle V_k \Lambda_k^{-\frac{1}{2}} \end{aligned} \quad (11)$$

这样就避免了 MDS 方法不能为新样本直接提供预测的缺点。

3 核 CMDS

为了提高 CMDS 处理数据中的非线性问题的性能,本小节提出 CMDS 的核形式,我们称为 KCMDS。假设核映射通过一个非线性映射 Φ 将原始欧氏空间 R^n 映射到一个特征希尔伯特空间 H , 即 $\Phi: R^n \rightarrow H$ 。设 $\Phi(X) = [\Phi(x_1) \ \Phi(x_2) \ \cdots \ \Phi(x_n)]^T$ 表示映射后特征空间的数据矩阵。为描述方便,假设映射后数据集 $\Phi(X)$ 是中心化的,即 $\sum_{i=1}^n \Phi(x_i) = 0$ 。可以证明,非中心化情形同样适用。在映射后特征空间中的相似性矩阵为 $\bar{D} = \{d_{ij}\}$, 其中

$$d_{ij} = \left\langle \frac{\Phi(x_i)}{\|\Phi(x_i)\|}, \frac{\Phi(x_j)}{\|\Phi(x_j)\|} \right\rangle = \frac{k(x_i, x_j)}{\sqrt{k(x_i, x_i)k(x_j, x_j)}} \quad (12)$$

该核函数是一个正规化核。几何上,正规化核将数

据映射到希尔伯特空间中一个半径为 1 的超球体。需要指出的是, RBF 核函数 $K(x, y) = \exp\left(-\frac{\|x - y\|^2}{c}\right)$ 是一个自然正规化核。若记正规化核矩阵为 K_s , 则有 $\bar{D} = K_s$ 。然后通过求解以下特征值问题求得特征空间中 X 的坐标

$$K_s v = \lambda v \quad (13)$$

令 $v^k = (v_1, v_2, \dots, v_k)$ 表示式(13)的解,对应特征值为 $\Lambda^k = [\lambda_1, \lambda_2, \dots, \lambda_k]$, 其中 $\lambda_1, \lambda_2, \dots, \lambda_k$ 为 K_s 的前 k 个较大的特征值。由式(10)可得,样本集 X 在低维特征空间的表示为

$$\left\langle \frac{\Phi(X)}{\|\Phi(X)\|}, \frac{\Phi(X)}{\|\Phi(X)\|} \right\rangle v^k \text{diag}(\Lambda^k)^{-\frac{1}{2}} = K_s v^k \text{diag}(\Lambda^k)^{-\frac{1}{2}} \quad (14)$$

对于一个新测试样本 \tilde{x} , 可以直接利用式(14)计算出其低维描述

$$\left\langle \frac{\Phi(\tilde{x})}{\|\Phi(\tilde{x})\|}, \frac{\Phi(X)}{\|\Phi(X)\|} \right\rangle v^k \text{diag}(\Lambda^k)^{-\frac{1}{2}} = K_{\text{test}} v^k \text{diag}(\Lambda^k)^{-\frac{1}{2}} \quad (15)$$

式中, $K_{\text{test}} \in R^n, K_{\text{test}}(i) = \left\langle \frac{\Phi(\tilde{x})}{\|\Phi(\tilde{x})\|}, \frac{\Phi(x_i)}{\|\Phi(x_i)\|} \right\rangle$, x_i 代表训练样本。

4 实验结果

本节设计实验检验 CMDS 降维效果。采用选择最近邻法分类器,以欧氏距离作为距离度量标准。

4.1 数据可视化实验

数据可视化是非监督子空间学习的一个重要应用点。本实验使用 TDT2 数据库中一个文本数据的子集进行实验。该集合包含从 5 类数据中随机选择出的 500 个文本文件。每个文件表示为一个由单词构成的向量,文件数据稀疏且维度为 36 771 (每个单词字母数量之和)。可视化的目标是将高维数据映射向低维描述,通过实验将数据映射到 2 维空间。各种方法映射结果如图 1 所示。由图 1(a)可以看出,CMDS 映射结果中,相同主题的文本映射分布紧密而不同主题文本映射之间稀疏。同时,CMDS 方法映射得到的结果聚类结构更为明显。

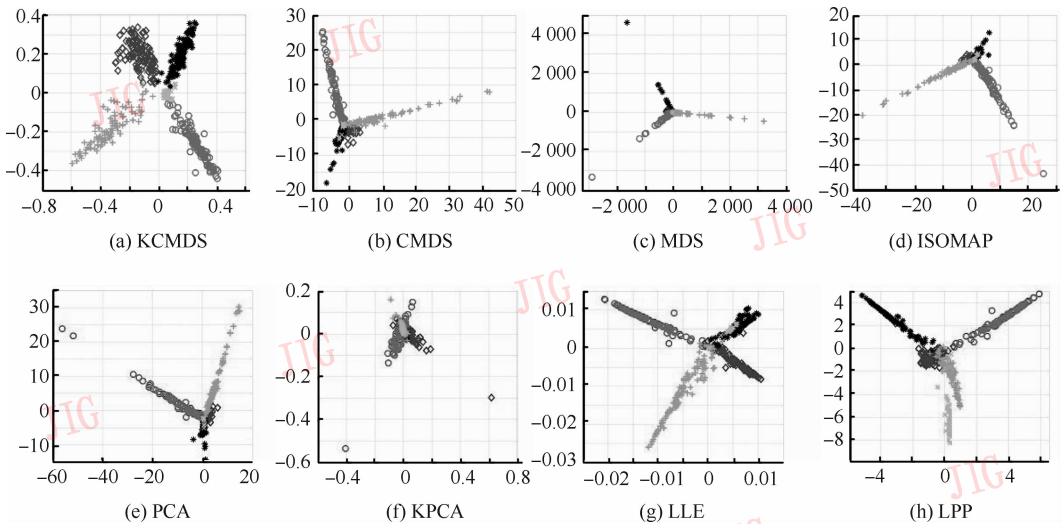


图 1 TDT2 文本数据库实验结果

Fig. 1 The results of different algorithms on TDT2 text data

4.2 人脸识别

利用人脸识别数据库检验 CMDS 效果。实验使用数据库为 Yale, CMU-PIE^[19] 和 GTdb 人脸数据库^[20]。3 个数据库的细节信息分别描述如下。

Yale 人脸数据库: 包含 15 人 165 幅灰度人脸图片, 每人 11 幅。图片是在不同光照(左侧光照, 中间光照, 右侧光照), 不同遮挡(有、无佩戴眼镜), 不同表情(正常, 欢乐, 悲伤, 睡眠, 惊奇, 友好)等情况下拍摄。图片大小为 320×243 像素。所有图片均根据图片内部结构(如眉毛, 眼睛, 鼻子和嘴)裁剪, 重新放缩到 64×64 像素。

CMU-PIE 人脸数据库: 该数据库包含 68 个个体, 共 41 368 张图片。数据通过 13 台同步相机在不同姿态、光照和表情下获得。选择子集 C09 作为测试, 每个对象在不同光照、表情下的正面图片。实验中所有图片放缩为 64×64 像素。

GTdb 人脸数据库: 包含 50 个对象共 750 张图片, 照片在 06/01/99 到 11/15/99 期间在乔治亚理工学院信号与图像处理中心拍摄。每个对象有 15 幅背景杂乱的 640×480 像素大小的彩色 JPEG 图片, 人脸图像的平均大小为 150×150 像素。这些正面图片有不同的面部表情、光照和尺寸。实验中首先利用 MATLAB 中的“rgb2gray”将图片转换为灰度图像, 然后缩放为 40×60 像素。

实验利用识别正确率检验提出算法 CMDS, KCMDS 和其他算法(PCA, KPCA 和 LPP)对比的效果。在 KPCA 中选择线性核函数 $k(x, y) = x^T y$ 和

高斯核函数 $k(x, y) = \exp\left(-\frac{\|x - y\|^2}{\sigma}\right)$, 分别用 KL-PCA 和 KG-PCA 表示。同样, 在 KCMDS 中也使用高斯核函数, 用 KG-CMDS 表示。在 LPP 中使用高斯核权重构造 12 近邻图。

实验中, 随机选择 N 幅图片作为训练(Yale, $N = 4, 8$; PIE, $N = 8, 12$; GTdb, $N = 5, 8$), 剩余图片作为测试。实验重复 50 次, 实验结果均值和标准差见表 1 上半部分。由表 1 可见, KG-CMDS 和 CMDS 在 3 个数据库中均取得最高识别率。实验结果验证了关联度量可以有效提取嵌入在相似性数据间的非线性流形结构的优点。由实验结果还可以看出, 所有使用正规化核的算法, 如 KG-PCA, KG-CMDS 和 CMDS(等价于 KPCA 使用线性正规化核)识别率均高于使用线性核算法(KL-PCA)的对应识别率。由此可知, 特征空间中使用正规化有利于提高识别率^[21]。

4.3 UCI 数据库

在本节实验中, 使用 UCI 机器学习数据库中的“multiple-feature digit data set (mdd)”检验 CMDS 和 KG-CMDS 的效果, 同时与 PCA, KL-PCA, KG-PCA 和 LPP 进行比较。该数据库包含“0”到“9”的手写数字图像。这些数据来自于荷兰实用地图库, 每类 200 个模式, 共 2 000 个模式。这些数字图像由多组特征集组成。第 1 组是“MDD-fou”, 代表图像的 76 个傅里叶分解系数。第 2 组是“MDD-fac”, 描述图片的 216 个属性相关性。第 3 类是“MDD-kar”, 表

示图片的 64 维 PCA 降维描述。第 4 类是“MDD-pix”,由图片所有 2×3 像素窗口的均值组成,共 240 维。第 5 类是“MDD-zer”,由 Zernike 矩组成,共 47 维。所有 5 类特征共同组成一个 643 维空间,定义为“MDD”。

随机选择每类 50 个图片作为训练,剩余作为测

试。实验同样重复 50 次,取均值和标准差作为实验最终结果,见表 1 下部分。由实验结果可以看出,CMDS 类方法识别率优于其他传统降维方法。同时,使用正规化核的方法 KG-PCA,CMDS 和 KG-CMDS 取得较好的效果。其次,线性核 PCA 算法在“MDD-pix”和“MDD-kar”中效果较优。

表 1 不同非监督降维方法在 4 个数据库 (Yale、PIE、GTdb 和 MDD) 中的识别率

Tab. 1 The recognition accuracies of different unsupervised dimensionality reduction methods on four face database (Yale, PIE, GTdb and MDD)

Data set	N	PCA	KL-PCA	KG-PCA	LPP	CMDS	KG-CMDS
Yale	4	74.46(5.25)	69.64(7.81)	75.67(5.61)	71.18(6.79)	76.61(4.74)	76.80(4.80)
Yale	8	78.00(10.16)	73.82(13.04)	78.04(10.67)	76.31(12.47)	78.98(10.12)	80.40(10.67)
CMU PIE	8	91.35(6.56)	79.62(13.39)	89.42(8.04)	91.41(5.58)	92.89(5.00)	91.34(6.34)
CMU PIE	12	94.14(5.71)	86.64(7.92)	94.20(5.85)	92.44(5.25)	94.46(4.76)	94.60(5.83)
GTdb	5	66.40(1.93)	53.55(2.70)	71.10(2.14)	52.35(1.96)	66.52(1.85)	71.72(2.24)
GTdb	8	73.35(1.98)	58.75(2.74)	78.06(1.60)	68.11(2.17)	73.29(1.99)	78.41(1.69)
MDD-pix	50	94.76(0.53)	92.11(0.78)	94.87(0.62)	89.36(0.79)	95.95(0.56)	96.30(0.50)
MDD-fou	50	80.62(0.91)	65.74(1.55)	81.02(0.94)	76.82(1.01)	80.84(0.85)	81.40(0.86)
MDD-fac	50	92.53(0.45)	70.79(2.37)	91.29(0.66)	91.38(1.39)	92.49(0.56)	93.87(0.56)
MDD-kar	50	95.09(0.43)	94.09(0.58)	95.13(0.50)	93.38(0.55)	95.07(0.54)	95.64(0.42)
MDD-zer	50	79.54(0.89)	66.68(1.49)	78.51(0.85)	77.73(1.37)	79.80(0.77)	80.01(0.96)
MDD	50	90.37(0.68)	76.52(2.79)	93.30(0.63)	94.37(0.68)	94.59(0.60)	94.84(0.45)

5 结论

提出基于关联度量的多维尺度分析 (CMDS),并将其应用于非监督子空间降维学习中。与传统的多维尺度分析相比,CMDS 通过在原始空间和低维空间使用非线性映射和相似性度量,能够有效解决新样本的预测问题,同时可以更好地获得原始数据中的非线性流形结构。此外,CMDS 还可以利用核方法扩展为 KCMDS,从而更好解决非线性问题。实验结果验证了 CMDS 及 KCMDS 的有效性。

参考文献 (References)

[1] Cox T F, Cox M A A. Multidimensional Scaling [M]. 2nd ed. London: Chapman & Hall, 2001: 124-127.
 [2] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290 (5500): 2323-2326.
 [3] Niyogi P. Laplacian eigenmaps for dimensionality reduction and

data representation [J]. Neural Computation, 2003, 15 (6): 1373-1396.

[4] Jolliffe I T. Principal Component Analysis [M]. 2nd ed. New York: Springer, 2002: 87-93.
 [5] He X, Niyogi P. Locality Preserving Projections [M]. Massachusetts, USA: MIT Press, 2003: 135-139.
 [6] Ham J H, Lee D D, Saul L K. Learning high dimensional correspondences from low dimensional manifolds [C] // Proceedings of International Conference on Machine Learning (ICML2003). California, USA: AAAI Press, 2003, 34 (2): 577-584.
 [7] Seung H S, Lee D D. The manifold ways of perception [J]. Science, 2000, 290 (5500): 2268-2269.
 [8] Polzlbauer G, Lidy T, Rauber A. Decision manifolds—a supervised learning algorithm based on self-organization [J]. IEEE Transactions on Neural Networks, 2008, 19 (9): 1518-1530.
 [9] Venna J, Kaski S. Local multidimensional scaling [J]. Neural Network, 2006, 19 (6): 889-899.
 [10] Tenenbaum J B, Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290 (5500): 2319-2323.
 [11] Kumar B V K V, Mahalanobis A, Juday R D. Correlation Pattern

- Recognition [M]. Cambridge: Cambridge University Press, 2006:62-71.
- [12] Haroon D R, Szedmak S R, Taylor J S. Canonical correlation analysis: An overview with application to learning methods [J]. Neural Computation, 2004, 16(12) :2639-2664.
- [13] Fu Y, Yan S, Huang T S. Correlation metric for generalized feature extraction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(12) :2229-2235.
- [14] Krichen E, Garcia-Salicetti S, Dorizzi B. A new phase-correlation-based iris matching for degraded images [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2009, 39(4) : 924-934.
- [15] Schölkopf B, Smola A. Learning with Kernels Support Vector Machines, Regularization, Optimization and Beyond [M]. Massachusetts, U S A; MIT Press, 2002; 53-58.
- [16] Liu Qingshan, Lu Hanqing, Ma Songde. Improving kernel fisher discriminant analysis for face recognition [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2004, 14(1) :42-49.
- [17] Herbrich R, Graepel T. A Pac-Bayesian margin bound for linear classifiers [J]. IEEE Transactions on Information Theory, 2002, 48(12) :3140-3150.
- [18] Wang L. Feature selection with kernel class separability [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(9) :1534-1546.
- [19] Sim T, Baker S, Bsat M. The cmu pose, illumination, and expression database [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(12) :1615-1618.
- [20] Nefian A V, Hayes M H III. Maximum likelihood training of the embedded HMM for face detection and recognition [C] // Proceedings of International Conference on Image Processing. New Jersey, 2000, USA; IEEE Press, 2000, 1(1) : 33-36.
- [21] Graf A B A, Smola A J, Borer S. Classification in a normalized feature space using support vector machines [J]. IEEE Transactions on Neural Networks, 2003, 14(3) : 597-605.