

DOI: 10.11830/ISSN.1000-5013.201601015



# 采用邻域关联性的非监督 流形对齐算法

徐猛, 王靖, 杜吉祥

(华侨大学 计算机科学与技术学院, 福建 厦门 361021)

**摘要:** 假设对于两个流形上关联性较强的样本点,其邻域点之间也会具有较强的关联性.基于此假设,提出一种新的非监督流形对齐算法,通过学习局部邻域之间的关联性,挖掘不同流形样本点间的关联性;然后,将两个流形样本点投影到共同的低维空间,同时保持所挖掘的关联性.结果表明:与传统的非监督流形对齐算法比较,文中算法能更准确地找出不同流形数据在低维空间的匹配点.

**关键词:** 流形对齐; 关联性; 局部邻域; 非监督

**中图分类号:** TP 301.6      **文献标志码:** A      **文章编号:** 1000-5013(2018)02-0256-06

## Unsupervised Manifold Alignment Algorithm Using Neighborhood Correlation

XU Meng, WANG Jing, DU Jixiang

(College of Computer Science and Technology, Huaqiao University, Xiamen 361021, China)

**Abstract:** This paper propose a basic assumption: for the points sampled from two manifolds which have strong correlations, their neighbors also have stronger correlations. Based on this assumption, this paper propose a new unsupervised manifold alignment algorithm which using the local neighborhood correlation to construct the relationship between the data sample points from different manifolds, and then projecting two manifold data to a common low-dimensional space while preserve the discovering of the correlation. The numerical experiments show that compared with the traditional unsupervised manifold alignment algorithms, this proposed algorithm can find the matching points of different manifold data in the low-dimensional space more accurately.

**Keywords:** manifold alignment; correlation; local neighborhood; unsupervised

如何提取高维数据之间隐藏的本质特征,是模式识别领域研究中面临的一个重要问题.近年来,流形学习通过降维提取高维数据的非线性特征,受到学者们的广泛关注<sup>[1-4]</sup>.代表性的算法有拉普拉斯特征映射、局部线性嵌入算法等<sup>[5-6]</sup>.尽管这些流形学习算法在机器学习<sup>[7]</sup>、模式识别、计算机视觉等领域得到广泛应用,但只能对来自单一流形的数据进行降维.在现实应用中,往往需要处理多个数据集<sup>[8-9]</sup>.为了挖掘多个数据集的非线性特征,学者们提出了一系列的流形对齐算法<sup>[10-15]</sup>.总体而言,在流形对齐

**收稿日期:** 2016-01-10

**通信作者:** 王靖(1981-),男,教授,博士,主要从事模式识别、推荐系统的研究. E-mail: wroaring@hqu.edu.cn.

**基金项目:** 国家自然科学基金资助项目(61370006);福建省自然科学基金资助项目(2014J01237);福建省教育厅科技项目(JA12006);福建省高等学校新世纪优秀人才支持计划(2012FJ-NCET-ZR01);华侨大学中青年教师科技创新资助计划(ZQN-PY116)

算法中,不同流形数据集上样本点之间的关联性挖掘是决定流形对齐效率的关键步骤.特别是在非监督流形对齐算法中,没有已知的对应信息,通过挖掘样本点的局部结构构造两个流形之间的关联性直接决定了流形对齐的效果.提出一个基本的假设:对于两个流形上关联性较强的样本点,其邻域点之间也会具有较强的关联性.基于此假设,本文设计一种新的非监督流形对齐算法.

## 1 流形对齐算法框架

给定两个采自流形  $X, Y$  上数据集,  $X = \{x_1, \dots, x_m\}, Y = \{y_1, \dots, y_n\}$ . 其中,  $X \in \mathbf{R}^{p_x \times m}, Y \in \mathbf{R}^{p_y \times n}$ . 流形对齐算法的目的:分别找到数据集  $X$  的低维嵌入坐标  $S = [s_1, \dots, s_m] \in \mathbf{R}^{d \times m}$  和数据集  $Y$  的低维嵌入坐标  $T = [t_1, \dots, t_n] \in \mathbf{R}^{d \times n}$ ,并在共同的低维空间中保持流形的结构和样本点之间的关联性,即通过计算最小化成本函数,得到嵌入结果,即

$$C(s, t) = u \sum_{i,j} (s_i - t_i)^2 W_{i,j}^{x,y} + 0.5 \sum_{i,j} (s_i - s_j)^2 W_{i,j}^x + 0.5 \sum_{i,j} (t_i - t_j)^2 W_{i,j}^y. \tag{1}$$

式(1)中: $u$  为平衡因子; $W_{i,j}^{x,y}$  为流形  $X, Y$  上样本点  $x_i, y_j$  之间的关联性; $W_{i,j}^x$  为流形  $X$  上样本点  $x_i, x_j$  的相关性; $W_{i,j}^y$  为流形  $Y$  上样本点  $y_i, y_j$  的相关性.

流形对齐算法根据是否给出已知对应点的信息,可以构造流形之间不同的关联性  $W_{i,j}^{x,y}$ .

1) 在半监督的流形对齐算法中,给出已知对应点信息  $x_i \leftrightarrow y_j$ ,构造  $W_{i,j}^{x,y}$ ,即

$$W^{x,y} = (W_{i,j}^{x,y}) = \begin{cases} 1, & x_i \text{ 和 } y_j \text{ 对应点,} \\ 0, & \text{其他.} \end{cases}$$

2) 在非监督的流形对齐算法中,由于没有给出已知对应点的信息,两个流形样本点之间的关联性挖掘决定了算法的有效性. Wang 等<sup>[14]</sup>提出的算法利用  $k$  个近邻点的局部欧式距离矩阵表示局部结构,并以此计算不同流形样本点的关联性.但是这种关联性的计算需要进行  $k!$  次的局部结构匹配,计算代价较大.在 Pei 等<sup>[15]</sup>提出的算法中,该方法对每个流形中样本点的邻域排序,通过用参数化距离曲线构造邻域曲线.然后,比较不同流形中的样本点邻域的曲线积分找到流形之间的对应关系,从而得到最终的对齐结果.

半监督和非监督流形对齐算法可以从实例层或特征层上获取数据的低维嵌入坐标<sup>[12-13]</sup>.实例层通过求解优化模型(1),直接计算每个样本点的低维嵌入坐标  $S, T$ . 首先,特征层获得每个输入数据集的低维映射函数  $F_x, F_y$ ,即

$$C(F_x, F_y) = u \sum_{i,j} (F_x^T x_i - F_y^T y_j)^2 W_{i,j}^{x,y} + 0.5 \sum_{i,j} (F_x^T x_i - F_x^T x_j)^2 W_{i,j}^x + 0.5 \sum_{i,j} (F_y^T y_i - F_y^T y_j)^2 W_{i,j}^y. \tag{2}$$

然后,将数据集映射到低维空间,得到低维嵌入坐标  $S, T$ . 因为映射函数可以很容易推广到新的测试样本中,所以特征层对齐在处理新的样本时,比实例层对齐更加有效.在此流形对齐算法的基本框架下,设计新的非监督流形对齐算法.

## 2 非监督流形对齐算法

对于两个不同流形中的样本点  $x_i, y_j$ ,现有的非监督流形对齐方法大多是通过比较流形局部结构相似性,以挖掘  $x_i, y_j$  之间的关联性<sup>[14-15]</sup>.然而,由于样本数据分布不均匀及噪声数据的存在等原因,这种关联性的挖掘也许并不准确.显然,如果  $x_i, y_j$  具有很强的关联性,则它们的邻域点之间也应该具有较强的关联性.

此外,如果  $x_i, y_j$  的邻域点之间的关联性较弱,则  $x_i, y_j$  之间的关联性也应该较弱.基于此基本的假设,提出一种  $x_i, y_j$  的邻域关联性的挖掘方法,将两个流形样本点投影到共同的低维空间,同时保持所挖掘的关联性.文中算法的流程图,如图 1 所示.

### 2.1 算法步骤

步骤 1 构造流形  $X, Y$  各自样本点之间的相关性  $W_{i,j}^x$  和  $W_{i,j}^y$ .




图 1 算法流程图

Fig. 1 Algorithm flow chart

对于  $x_i \in X, y_j \in Y$ , 用  $d_{i,j}^x$  和  $d_{i,j}^y$  分别表示流形  $X$  上样本点  $x_i$  与  $x_j$  的欧式距离、流形  $Y$  上样本点  $y_i$  与  $y_j$  的欧式距离, 即

$$d_{i,j}^x = \|x_i - x_j\|_2, \quad d_{i,j}^y = \|y_i - y_j\|_2.$$

则流形  $X, Y$  各自样本点之间的相关性  $W_{i,j}^x, W_{i,j}^y$  可以利用相应的欧式距离构造, 即

$$W_{i,j}^x = \begin{cases} \exp(-(d_{i,j}^x)^2/\sigma^2), & x_j \in N(x_i), \\ 0, & \text{其他}, \end{cases} \quad W_{i,j}^y = \begin{cases} \exp(-(d_{i,j}^y)^2/\sigma^2), & y_j \in N(y_i), \\ 0, & \text{其他}. \end{cases}$$

其中:  $N(x_i) = \{x_{i_1}, \dots, x_{i_k}\}, N(y_j) = \{y_{j_1}, \dots, y_{j_k}\}$  分别表示样本点  $x_i, y_j$  的  $k$ -近邻.

步骤 2 构造流形  $X, Y$  样本点之间的关联性  $W_{i,j}^{x,y}$ .

步骤 3 计算最优的嵌入结果(实例层)或映射函数(特征层).

令  $\Omega_1^{i,i} = \sum_j W_{i,j}^{x,y}, \Omega_2^{i,j} = \sum_j W_{i,j}^{x,y}, \Omega_3^{i,j} = \sum_j W_{j,i}^{x,y}, \Omega_4^{i,i} = \sum_j W_{j,i}^{x,y}$ , 定义

$$L = \begin{bmatrix} L^x + \mu\Omega_1 & -\mu\Omega_2 \\ -\mu\Omega_3 & L^y + \mu\Omega_4 \end{bmatrix}.$$

其中:  $L^x = D^x - W^x; L^y = D^y - W^y; D_{i,i}^x = \sum_j W_{i,j}^x; D_{i,i}^y = \sum_j W_{i,j}^y$ .

对于实例层, 通过以上定义, 式(1)模型可以转化为

$$C(s, t) = \text{trace}([S \ T]L \begin{bmatrix} S \\ T \end{bmatrix}) = \text{trace}(\gamma L \gamma^T). \tag{3}$$

令  $D = \begin{bmatrix} D^x & 0 \\ 0 & D^y \end{bmatrix}$ , 式(3)的最小化问题可以转化为求解  $L\gamma = \lambda D\gamma$  的最小特征值对应的前  $d$  个特征向量, 即  $\begin{bmatrix} S \\ T \end{bmatrix} = [\gamma_1, \dots, \gamma_d]^T$  表示样本在低维中的嵌入结果.

对于特征层, 通过上面的定义, 式(2)模型可以转化为

$$C(F_x, F_y) = \text{trace}([F_x^T X F_y^T Y]L \begin{bmatrix} X^T & F_x \\ Y^T & F_y \end{bmatrix}) = \text{trace}(\gamma Z L Z^T \gamma^T). \tag{4}$$

令  $Z = \begin{bmatrix} X & 0 \\ 0 & Y \end{bmatrix}$ , 式(4)的最小化问题可转化为求解  $Z L Z^T \gamma = \lambda Z L Z^T \gamma$  的最小特征值对应的前  $d$  个特征向量, 即  $[F_x^T, F_y^T] = [\gamma_1, \dots, \gamma_d]$  表示低维映射函数  $F_x^T$  和  $F_y^T$ , 则  $X, Y$  在  $d$  维空间中分别表示为  $S = F_x^T X, T = F_y^T Y$ .

2.2 流形之间的关联性构造

对于两个流形的样本点  $x_i, y_j$ , 先用参数化距离曲线表示  $x_i, y_j$  的邻域曲线, 以此计算  $x_i, y_j$  初始化的关联性, 即  $\bar{W}_{i,j}^{x,y}$ . 当  $x_i, y_j$  的关联性较强时, 其邻域  $N(x_i), N(y_j)$  也应该具有较强的关联性. 基于此假设, 提出一种邻域关联性的挖掘方法, 利用  $\bar{W}_{i,j}^{x,y}$  挖掘邻域  $N(x_i), N(y_j)$  之间的关联性  $\hat{W}_{i,j}^{x,y}$ . 最后, 基于初始关联性  $\bar{W}_{i,j}^{x,y}$  和邻域关联性  $\hat{W}_{i,j}^{x,y}$ , 重新学习  $x_i$  和  $y_j$  之间的关联性  $W_{i,j}^{x,y}$ .

2.2.1 两个流形样本点之间的关联性构造 首先, 构造向量表示两个流形的样本点  $x_i, y_j$  的局部结构. 文中用样本点到其局部邻域点的欧式距离表示其局部结构, 即构造离散距离向量, 有

$$\bar{V}_{x_i} = [d_{i,i_1}^x, \dots, d_{i,i_k}^x], \quad \bar{V}_{y_j} = [d_{j,j_1}^y, \dots, d_{j,j_k}^y].$$

其中:  $d_{i,i_p}^x, d_{j,j_q}^y$  分别表示  $x_i, y_j$  到其邻域  $x_{i_p}, y_{j_q}$  的欧式距离,  $p, q = 1, \dots, k$ .

其次, 计算两个距离向量的差异性  $\bar{S}_{i,j}^{x,y}$ . 借鉴文献[15]的思想, 用 B-样条(B-spline)曲线  $\mathbf{g}_i^x, \mathbf{g}_j^y$  分别拟合流形  $X$  上的样本点  $x_i$  的离散距离向量  $\bar{\mathbf{V}}_{x_i}$  和流形  $Y$  上的样本点  $y_j$  的离散距离向量  $\bar{\mathbf{V}}_{y_j}$ , 即

$$\mathbf{G}^x = \{\mathbf{g}_i^x \mid i = 1, \dots, m\}, \quad \mathbf{G}^y = \{\mathbf{g}_j^y \mid j = 1, \dots, n\},$$

则流形  $X, Y$  上样本点  $x_i, y_j$  局部结构之间的差异性  $\bar{S}_{i,j}^{x,y}$  为

$$\bar{S}_{i,j}^{x,y} = \int_0^k (|\mathbf{g}_i^x - \mathbf{g}_j^y| + \varphi |\nabla \mathbf{g}_i^x - \nabla \mathbf{g}_j^y|) dx. \quad (5)$$

式(5)中: 常量  $\varphi$  为平衡因子;  $\nabla \mathbf{g}_i^x, \nabla \mathbf{g}_j^y$  分别表示  $\mathbf{g}_i^x, \mathbf{g}_j^y$  曲线的梯度.

最后, 利用差异性  $\bar{S}_{i,j}^{x,y}$  构造  $x_i, y_j$  的关联性  $\bar{W}_{i,j}^{x,y}$ . 如果  $\bar{S}_{i,j}^{x,y}$  很大, 即样本点  $x_i, y_j$  的局部结构差异性很大, 则它们之间的关联性权值  $\bar{W}_{i,j}^{x,y}$  就应该很小. 因此, 引入热核函数计算  $x_i, y_j$  的关联性  $\bar{W}_{i,j}^{x,y}$ , 即

$$\bar{W}_{i,j}^{x,y} = \exp(-(\bar{S}_{i,j}^{x,y})^2 / \sigma^2). \quad (6)$$

2.2.2 两个流形样本点邻域之间的关联性构造 记  $R_{i,i_p}$  为  $x_i$  与其邻域点  $x_{i_p} \in N(x_i)$  之间的相关性,  $\text{Sim}(x_{i_p}, N(y_j))$  为  $x_{i_p}$  与  $y_j$  的邻域  $N(y_j)$  之间的关联性, 则邻域  $N(x_i), N(y_j)$  之间的关联性为  $R_{i,i_p}$  与  $\text{Sim}(x_{i_p}, N(y_j))$  的加权平均. 即

$$\tilde{W}_{i,j}^{x,y} = \frac{\sum_{p=1}^k R_{i,i_p} \text{Sim}(x_{i_p}, N(y_j))}{\sum_{p=1}^k R_{i,i_p}}. \quad (7)$$

对  $x_i$  与其邻域点  $x_{i_p}$  的相关性  $R_{i,i_p}$ , 可利用欧式距离  $d_{i,i_p}^x$  定义为  $R_{i,i_p} = \exp(-(d_{i,i_p}^x)^2 / \sigma^2)$ . 显然, 距离越近, 则相关性越大, 反之则越小.

对于  $x_{i_p}$  与  $y_j$  的邻域  $N(y_j)$  之间的关联性  $\text{Sim}(x_{i_p}, N(y_j))$ , 由于  $x_{i_p}$  与  $y_j$  的邻域点之间的关联性无法利用欧式距离直接度量, 可利用节 2.2.1 计算的样本点关联性进行构造. 记  $\bar{W}_{i_p,j_q}^{x,y}$  表示  $x_{i_p}$  与  $y_j$  的邻域点  $y_{j_q}$  的关联性, 则  $\text{Sim}(x_{i_p}, N(y_j))$  可以构造为

$$\text{Sim}(x_{i_p}, N(y_j)) = \min_{q=1, \dots, k} \bar{W}_{i_p,j_q}^{x,y}. \quad (8)$$

式(8)的构造符合文中假设, 即如果  $x_{i_p}$  与  $y_j$  的每个邻域点  $y_{j_q}$  都有较大的关联性, 则可以认为  $x_{i_p}$  与邻域  $N(y_j)$  具有较大的关联性. 综合考虑两个流形样本点之间的关联性和其邻域之间的关联性, 可以得到  $X, Y$  流形之间的关联性  $W_{i,j}^{x,y}$ , 即

$$W_{i,j}^{x,y} = (\bar{W}_{i,j}^{x,y} + \tilde{W}_{i,j}^{x,y}) / 2. \quad (9)$$

### 3 数值实验

首先, 在 COIL-20 数据库和 LFW 数据库上进行非监督流形对齐算法的对比实验. 在对比实验中, 主要验证基于非监督流形对齐的通用模型(1), 不同关联性挖掘算法的有效性. 进行对比实验的关联性挖掘算法为基于局部欧式距离矩阵的关联性挖掘算法(UNMA)<sup>[14]</sup>和基于局部拟合曲线的关联性挖掘算法(Y. Pei' method)<sup>[15]</sup>.

#### 3.1 度量方式

对于两个图像的数据集, 一是目标域的数据集  $X = \{x_i \mid i = 1, \dots, m\}$ , 二是辅助域的数据集  $Y = \{y_j \mid j = 1, \dots, n\}$ . 为了对结果进行量化度量, 提出以下 2 种度量方式.

1) 在 COIL-20 数据库中, 对于目标域中的每个  $x_i$ , 如果辅助域中的图像  $y_j$  为其在投影空间中的最近点, 则  $y_j$  视为  $x_i$  的匹配图像. 如果  $x_i$  与  $y_j$  的角度差  $|\theta_{x_i} - \theta_{y_j}|$  不超过某个给定的  $\theta$ , 则  $y_j$  视为  $x_i$  的准确匹配图像. 因此, 提出基于角度差  $\theta$  的匹配准确率概念, 基于  $\theta$  的匹配准确率 = 准确匹配图像数目 / 目标领域图像数目.

2) 在 LFW 数据库中, 对于目标域中的每个  $x_i$ , 考虑它在辅助域图像集  $Y$  中最相似的  $r$  个图像点, 如果真正的匹配点存在于这  $r$  个图像中, 则视为匹配图像. 因此, 提出基于近邻点  $r$  的匹配准确率, 基于  $r$  的匹配准确率 = 匹配图像数目 / 目标领域图像数目.

3.2 非监督流形对齐实验

3.2.1 COIL-20 数据库 将流形对齐算法用于 COIL-20 数据库. 此数据库包含 20 个对象, 数据库共有 1 440 幅图像. 每幅图像大小为 128 px×128 px, 由相机围绕某个对象旋转 360°, 每次旋转 5° 拍摄而成. 将每张图像缩小成 32 px×32 px 的图像后, 再进行向量化, 由此得到 1 024 px×1 px 的向量. 选择 2 个对象进行实验, 部分图像如图 2 所示. 图 2 中: S 组图像是目标域图像集; T 组图像是辅助域图像集.




图 2 COIL-20 数据库中两个实验对象的部分图像

Fig. 2 Partial images of two experimental objects in COIL-20 database

用文中算法、Y. Pei' method 和 UNMA 算法对 COIL-20 数据库进行对比, 验证在邻域点个数为 11 个,  $d=10$ , 角度差  $\theta$  变化情况下, 3 种算法的图像匹配率( $\eta$ ), 如图 3 所示. 由图 3 可知: 相较于 UNMA 算法, Y. Pei' method 在通过参数化曲线表述样本点的局部结构情况下, 能提高图像匹配的准确率, 说明文中引入的参数化曲线能更有效地表述不同流形中样本点之间的关联性. 此外, 文中算法的匹配准确率明显高于 Y. Pei' method 和 UNMA 算法, 体现出关系模型的权值修改对流形对齐效果有重要影响, 进一步说明通过样本点邻域之间的关联性对原有的关联性修改起到非常关键的作用.

3.2.2 LFW 数据库 将流形对齐算法用于 LFW 数据库的 YouTube 视频数据集. 此视频数据集共有 1 595 个对象. 首先, 把每个对象的视频数据集的每一帧做人脸检测, 裁剪出以人脸为中心的 100 px×100 px 的图像. 然后, 进行灰度转换. 最后, 进行编码处理. 以 Abba\_Eban 为对象的视频集作为目标域图像集. 将 Cent-Symmetric LBP(CSLBP)<sup>[16]</sup> 编码处理后的视频集作为辅助域图像集.

用文中算法、Y. Pei' method 和 UNMA 算法对 YouTube 视频数据集进行对比, 验证在邻域点个数为 16 个,  $d=10$ , 近邻点个数  $r$  变化情况下, 3 种算法的图像匹配率, 如图 4 所示. 由图 4 可知: UNMA 算法的匹配准确率比较低. 这说明通过欧氏距离构建的局部结构来寻找流形间的对应关系不能很好地应用在这个实例中. 同时, 文中算法优于 Y. Pei' method 和 UNMA 算法, 进一步说明了文中算法在通过参数化曲线表述流形中样本点关联性的基础上, 再通过邻域之间的关联性做进一步的修正, 能提高匹配准确率, 体现算法的有效性.




图 3 在 COIL-20 数据库的匹配准确率

Fig. 3 Matching accuracies in COIL-20 database




图 4 在 LFW 数据库的匹配准确率

Fig. 4 Matching accuracies in LFW database

4 结束语

现有的非监督算法只是通过局部结构挖掘样本点关联性. 文中提出一种新的关联性挖掘算法, 利用

局部邻域之间的关联性对样本点的关联性进行二次修正,能更准确地找出两个流形之间的对应关系,并在实验中验证算法有效性.当数据采样非常稀疏,流形的局部邻域结构不明显时,文中算法有效性可能会受到限制,这也是今后的工作.

## 参考文献:

- [1] ZHAO Zhenhua,HAO Xiaohong. Linear locality preserving and discriminating projection for face recognition[J]. Journal of Electronics and Information Technology,2013,35(2):463-466. DOI:10.3724/SP.J.1146.2012.00601.
- [2] WANG Chang,MAHADEVAN S. A general framework for manifold alignment[C]//Proceeding of AAAI International Conference. Welty:[s. n.],2009:101-109.
- [3] HE Qing,CAI Hong,HAN Zhuangzhi,*et al.* ISAR target recognition based on nonlinear manifold learning [J]. Acta Electronica Sinica,2010,38(3):585-590.
- [4] MOULIN C,LARGERON C,DUCOTTET C,*et al.* Fisher linear discriminant analysis for text-image combination in multimedia information retrieval[J]. Pattern Recognition,2014,47(1):260-269. DOI:10.1016/j.patcog.2013.06.003.
- [5] BELKIN M,NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation,2003,15(6):1373-1396. DOI:10.1162/089976603321780317.
- [6] ROWEIS S T,SAUL L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science,2000,290(5500):2323-2326.
- [7] MARTINEZ A M,KAK A C. Pattern analysis and machine intelligence PCA versus LDA[J]. Transactions on Pattern Analysis and Machine Intelligence,2001,23(2):228-233.
- [8] LUNGA D,PRASAD S,CRAWFORD M,*et al.* Manifold learning based feature extraction for classification of hyper-spectral data: A review of advances in manifold learning[J]. Signal Processing Magazine,2014,31(1):55-66.
- [9] DIAZ F,METZLER D. Pseudo-aligned multilingual corpora[C]//International Joint Conference on Artificial Intelligence. Hyderabad:AAAI Press,2007:2727-2732.
- [10] HAM J,LEE D,SAUL L. Semi-supervised alignment of manifolds[C]//Proceedings of the International Workshop on Artificial Intelligence and Statistics. [S. l.]:ACM,2005:120-127.
- [11] XIONG Liang,WANG Fei,ZHANG Changshui. Semi-definite manifold alignment[M]. Berlin:Springer,2007:773-781.
- [12] WANG Chang,MAHADEVAN S. Manifold alignment using procrustes analysis[C]//Proceedings of the 25th International Conference on Machine Learning. Edinburgh:ACM,2008:1120-1127. DOI:10.1145/1390156.1390297.
- [13] WANG Chang,MAHADEVAN S. Manifold alignment preserving global geometry[C]//Proceedings of the 23th International Joint Conference on Artificial Intelligence. Florida:[s. n.],2013:1743-1749.
- [14] WANG Chang,MAHADEVAN S. Manifold alignment without correspondence[C]//Proceedings of the 21st International Joint Conference on Artificial Intelligence. Pasadena:[s. n.],2009:1273-1278.
- [15] PEI Yuru,HUANG Fengchun,SHI Fuhao,*et al.* Unsupervised image matching based on manifold alignment[J]. Transactions on Pattern Analysis and Machine Intelligence,2012,34(8):1658-1664.
- [16] HEIKKILA M,PIETIKAINEN M,SCHMID C. Description of interest regions with centersymmetric local binary patterns[C]//The Indian Conference on Computer Vision, Graphics and Image Processing. Madurai:[s. n.],2006:58-69.

(责任编辑:钱筠 英文审校:吴逢铁)