

基于多谱特征表示的点模式匹配算法

唐 俊 刘志忠 梁 栋 王 年

(安徽大学计算智能与信号处理教育部重点实验室, 安徽 合肥 230039)

摘要 针对单一的谱特征表示的局限性,提出了一种基于多谱特征表示的点模式匹配算法。利用图的不同矩阵的特征值序列作为特征点的描述子;借助多谱嵌入技术求解获得局部结构描述子的相似性;结合几何相容性,使用概率松弛的方法实现点模式匹配问题的求解。模拟数据和真实图像上的比较实验验证了该算法的有效性和稳健性。

关键词 机器视觉;匹配;谱图理论;局部结构描述子

中图分类号 TP391 **文献标识码** A **doi**: 10.3788/AOS201333.1215001

Point Pattern Matching Based on Multiple Spectral Representations

Tang Jun Liu Zhizhong Liang Dong Wang Nian

(Key Laboratory of Intelligent Computing and Signal Processing, Ministry of Education, Anhui University, Hefei, Anhui 230039, China)

Abstract Addressing the weakness of the single spectral representation, an algorithm is proposed for point pattern matching on the basis of multiple spectral representations. The eigenvalue series obtained by various matrix representations of graphs are used as the descriptor of feature point. The similarities between the given local structural descriptors are evaluated via the technique of multiview spectral embedding. Combined with the geometric consistency, point pattern matching problem is solved by using the method of probabilistic relaxation. Comparative experiments conducted on both synthetic data and real images verify the effectiveness and robustness of the proposed method.

Key words machine vision; matching; spectral graph theory; local structural descriptor

OCIS codes 100.5010; 150.1135; 330.5000

1 引 言

点模式匹配是模式识别和计算机视觉中的一个重要研究课题^[1-3],在图像配准、三维重建和目标识别等领域都有着广泛的应用。谱匹配是研究点模式匹配的重要方法,其基本思路是在待匹配点集上构造结构图,然后利用图的邻接矩阵或拉普拉斯矩阵等矩阵的谱特征求解点模式匹配问题。自 Scott 等^[4]的开创性工作后,众多学者提出了许多改进的方法。例如,为了克服 Scott 算法在较大角度旋转情况下匹配效果较差的缺点,Shapiro 等^[5]分别对待匹配点集构造高斯邻接矩阵并进行谱分解,通过比较得到的有序特征向量求解点集间的匹配关系。王

年等^[6]使用拉普拉斯矩阵的特征向量求解匹配问题。但这些方法在有随机位置抖动或出格点(Outlier)的情况下,匹配精度仍然较低。因而有研究者从不同的角度出发,将一些优化算法与谱匹配算法相结合,以期待获得更高的精度,如置于期望最大化(EM)算法的框架下^[7]、结合几何相容性分析^[8]等。也有研究者采用了与 Scott 算法、Shapiro 算法不同的思路。如 Leordeanu 等^[9]认为正确匹配点对间存在着强连通性,所有的正确匹配对可构成一个紧致的主聚类。在此前提下,他们对待匹配点集构造分配图,其中分配图的顶点表示正确匹配对,边表示匹配对间的相容性,并采用谱松弛的方法求解匹

收稿日期: 2013-05-26; **收到修改稿日期**: 2013-07-30

基金项目: 国家自然科学基金(11071002,61172127)、安徽省教育厅自然科学基金项目(KJ2011A008)、安徽大学 211 工程学术创新团队计划

作者简介: 唐 俊(1977—),男,博士,副教授,主要从事模式识别与计算机视觉等方面的研究。

E-mail: tangjunahu@163.com

配关系。Cour 等^[10]对 Leordeanu 算法进行了扩展,在匹配目标函数中施加了仿射变换约束。梁栋等^[11]用线图的拟拉普拉斯矩阵的谱序列(特征值序列)描述特征点的特征,从而避免了在点集大小不等时需对特征向量进行截断的问题^[4-5],但是,由于谱序列是对图的结构“粗略”描述,仅使用单一的拟拉普拉斯矩阵的谱并不具备很好的判别性。另外,图的不同矩阵(邻接矩阵、拉普拉斯矩阵及拟拉普拉斯矩阵)的谱是不同的,而且其表示的结构语义也不尽相同。Wilson 等^[12]将多种矩阵的谱组合应用于图像的聚类,其准确率要高于单一的谱。受此启发,针对文献[11]中单一的拟拉普拉斯矩阵的谱表示方法的局限性,本文将其拓展为一种基于多种谱表示的局部结构描述子:首先,对每个特征点的局部点集构图,分别求解图的邻接矩阵、拉普拉斯矩阵和拟拉普拉斯矩阵的特征值序列作为特征点的结构描述

子;然后利用多谱嵌入(MSE)的方法将多特征表示的谱描述子融合,并结合以近似距离序表示的几何相容性讨论如何求解匹配关系。

2 基本理论

2.1 图的若干基本概念

设图 $G = (V, E)$ 是含有 n 个顶点的简单无向图,其中 $V(G)$ 为顶点集, $E(G)$ 为边集。图的拉普拉斯矩阵定义为 $L = D - A$, 其中 A 为图的邻接矩阵, D 为图 G 的度矩阵, 即 $D_{ii} = \sum_j A_{ij}$ 。 $Q = D + A$ 称为图的拟拉普拉斯矩阵。将图 G 的边集作为顶点集变换而得到的图称为图 G 的线图, 当且仅当图 G 中对应的边有公共顶点时线图的顶点是邻接的。线图的变换过程如图 1 所示(左边为与顶点 v_1 相关联的边组成的星状图, 右边为其对应的线图)。




图 1 线图的生成

Fig. 1 Generation of line graph

2.2 多谱嵌入

在计算机视觉和模式识别中,为了能够充分表达目标的性质,往往采用多种类型的特征对目标进行描述。由于特征的提取方式不同,得到的特征表示向量也不尽相同,如何衡量多种特征之间的相似性成为有效利用多种特征的关键所在,一种可行的思路是将这些特征映射至低维空间,获得其在低维空间的一致性表示。MSE 算法^[13]是这种思想的典型实现,它能够有效地利用多种类型特征间的互补性质。下面对 MSE 算法进行简要的介绍,算法细节参见文献[13]。

设 $Z^{(i)} = [z_1^{(i)}, \dots, z_n^{(i)}]$, $i = 1, \dots, m$ 表示目标的第 i 个特征。首先对每个特征集 $Z^{(i)}$ 构造赋权完全图并求其拉普拉斯矩阵 $L^{(i)}$, 低维嵌入特征向量 F 可通过求解如下方程获得:

$$\begin{aligned} & \underset{F, \alpha}{\operatorname{argmin}} \sum_{i=1}^m \alpha_i^r \operatorname{tr}(\mathbf{F} \mathbf{L}^{(i)} \mathbf{F}^T) \\ & \text{s. t. } \mathbf{F} \mathbf{F}^T = \mathbf{I}, \quad \sum_{i=1}^m \alpha_i = 1, \quad \alpha_i \geq 0, \quad (1) \end{aligned}$$

其中权重系数 α 用来控制每种特征在低维嵌入过程

中的贡献度, α 越大,在低维嵌入过程中所占的比重越大。当 $\alpha_i = 1$ (或 0) 时,说明在低维嵌入过程中只用到(或没用到)这种特征。故引入指数 $r (r > 1)$ 控制不同特征间的相关性, r 值越大越能体现不同特征间的互补特性,越小越趋于单一的特征。(1) 式的最优解可通过引入拉格朗日乘数结合交替优化的方法求得。结合约束条件 $\sum_{i=1}^m \alpha_i = 1$, 拉格朗日函数定义为

$$L(\alpha, \lambda) = \sum_{i=1}^m \alpha_i^r \operatorname{tr}(\mathbf{F} \mathbf{L}_n^{(i)} \mathbf{F}^T) - \lambda \left(\sum_{i=1}^m \alpha_i - 1 \right), \quad (2)$$

式中 λ 为拉格朗日乘数。分别对 α, λ 求其偏导,令偏导为 0,可得系数 α_i 的更新公式:

$$\alpha_i = \frac{\{1/\operatorname{tr}[\mathbf{F} \mathbf{L}_n^{(i)} \mathbf{F}^T]\}^{1/(r-1)}}{\sum_{i=1}^m \{1/\operatorname{tr}[\mathbf{F} \mathbf{L}_n^{(i)} \mathbf{F}^T]\}^{1/(r-1)}}. \quad (3)$$

结合(1)式,(3)式的优化问题等价于

$$\min_Y \operatorname{tr}(\mathbf{F} \mathbf{L} \mathbf{F}^T) \quad \text{s. t. } \mathbf{F} \mathbf{F}^T = \mathbf{I}, \quad (4)$$

其中 $\mathbf{L} = \sum_{i=1}^m \alpha_i \mathbf{L}_n^{(i)}$, 根据 Ky-Fan 定理^[10], (4) 式的全

局最优解 F 由矩阵 L 的前 d 个最小特征值所对应的特征向量构成。

3 谱描述子及特征融合

3.1 谱描述子的构造

设待匹配点集为 $\mathbf{X} = \{x_i | i=1, 2, \dots, M\}$ 和 $\mathbf{Y} = \{y_j | j=1, 2, \dots, N\}$, $M \neq N$, 点集间的匹配关系记为 $\varphi: \mathbf{X} \Leftrightarrow \mathbf{Y}$ 。以特征点集 \mathbf{X} 为例, 对每个 $x_i \in \mathbf{X}$ 和给定整数序列 $\mathbf{K} = \{k_1, k_2, \dots, k_l\}$, 谱描述子构造方法

$$\mathbf{A}_i(p, q) = \begin{cases} \exp(-\|e_p - e_q\|^2 / 2\sigma^2) & p \neq q \\ 0 & p = q \end{cases} \quad e_p, e_q \in \mathbf{E}_i, \quad (5)$$

式中 e_p 为与点 p 相关联的边, 参数 σ 为平滑系数, 用来控制特征点之间的相互作用程度。并分别求线图 \mathbf{H}_i 的拉普拉斯矩阵 \mathbf{L}_i 和拟拉普拉斯矩阵 \mathbf{Q}_i 。

4) 分别对矩阵 \mathbf{A}_i , \mathbf{L}_i 和 \mathbf{Q}_i 进行奇异值分解 (SVD)。以 \mathbf{A}_i 为例, 经 SVD 分解后得到

$$\mathbf{A}_i = \mathbf{U}_i \mathbf{\Lambda}_i \mathbf{U}_i^T, \quad (6)$$

其中 \mathbf{U}_i 由矩阵 \mathbf{A}_i 特征向量构成, 矩阵 $\mathbf{\Lambda}_i$ 的对角线元素由矩阵 \mathbf{A}_i 的有序特征值的绝对值 (降序排列) 构成。于是, 可得到点集 Ω_i 的三种谱描述子向量:

$$\text{Spec}(\mathbf{A}_i^X) = \{|\lambda_{A_i}^1|, |\lambda_{A_i}^2|, \dots, |\lambda_{A_i}^{k_i}| \},$$

$$\text{Spec}(\mathbf{L}_i^X) = \{|\lambda_{L_i}^1|, |\lambda_{L_i}^2|, \dots, |\lambda_{L_i}^{k_i}| \},$$

$$\text{Spec}(\mathbf{Q}_i^X) = \{|\lambda_{Q_i}^1|, |\lambda_{Q_i}^2|, \dots, |\lambda_{Q_i}^{k_i}| \}, \quad (7)$$

式中 $|\lambda_i^k|$ 为矩阵 \mathbf{A} 的第 i 大的奇异值 (特征值的绝对值), $|\lambda_{L_i}^k|$, $|\lambda_{Q_i}^k|$ 的定义类似。同样, 对于特征点集 $y_j \in \mathbf{Y}$ 和 $k_l \in \mathbf{K}$ 同样可以获得三种谱描述子向量 $\text{Spec}(\mathbf{A}_{j_t}^Y)$, $\text{Spec}(\mathbf{L}_{j_t}^Y)$ 和 $\text{Spec}(\mathbf{Q}_{j_t}^Y)$ 。计算这种多特征描述子之间的相似性, 最简单的方法是直接将三个向量拼接成一个长向量, 通过向量间的欧式距离表示特征点的相似性, 然而, 这种方式往往忽略了每个特征的特有统计特性。为了充分利用特征点的多特征信息, 通过 MSE 算法对特征点集的多特征向量进行融合, 获得一个符合多特征间结构语义的低维嵌入特征向量。

3.2 谱特征融合

上节所获得的谱描述子向量可视为对特征点的多视图描述, 从 MSE 算法的目标函数来看, 其能直接对目标的多特征信息进行处理, 使得每种特征在低维嵌入过程中充分平滑, 从而实现了不同类型特征的互补, 发挥多特征描述的优势, 因此, 应用 MSE 算法对谱特征进行融合。对每个 $k_i \in \mathbf{K}$, $t = 1, 2,$

如下。

1) 对每个 $k_i \in \mathbf{K}$, 取与 x_i 最近邻的 k_i 个点构成集合 Ω_i 。

2) 对集合 Ω_i 构造赋权完全图, 边的权值定义为任意两点间的欧式距离, 取与 x_i 相关联的边组成星状图 $\mathbf{G}_i = (\mathbf{V}_i, \mathbf{E}_i)$ (如图 1)。

3) 将 \mathbf{G}_i 转变为与其相对应的线图 \mathbf{H}_i 。线图 \mathbf{H}_i 的邻接矩阵定义为

\dots, l , 分别对特征点 $x_i \in \mathbf{X}$ 和 $y_j \in \mathbf{Y}$ 构造谱描述子并将它们按如下方式组合:

$$\text{Spec}(\mathbf{Z}_i^1) = \begin{bmatrix} \text{Spec}(\mathbf{A}_i^X) \\ \text{Spec}(\mathbf{A}_{j_t}^Y) \end{bmatrix}, \text{Spec}(\mathbf{Z}_i^2) = \begin{bmatrix} \text{Spec}(\mathbf{L}_i^X) \\ \text{Spec}(\mathbf{L}_{j_t}^Y) \end{bmatrix},$$

$$\text{Spec}(\mathbf{Z}_i^3) = \begin{bmatrix} \text{Spec}(\mathbf{Q}_i^X) \\ \text{Spec}(\mathbf{Q}_{j_t}^Y) \end{bmatrix}, \quad (8)$$

算法如下所示。

输入: 谱特征 $\text{Spec}(\mathbf{Z}_i^p)$, $p=1, 2, 3$, 降维维数 d ($d < m$, m 为原特征维数), 权重指数 r , 最大迭代步数 N_{Itermax} 。

输出: 融合后的新特征 $\mathbf{F}_i \in R^{d \times (M+N)}$ 。

步骤:

1) 初始化参数 $\alpha_p = [1/3, 1/3, 1/3]$, 迭代步数为 1。计算 $\text{Spec}(\mathbf{Z}_i^p)$ 的归一化拉普拉斯矩阵 \mathbf{L}_i^p 。

2) $N_{\text{Iter}} = N_{\text{Iter}} + 1$, 计算融合矩阵 $\mathbf{L} = \sum_{p=1}^3 \alpha_p^r \mathbf{L}_i^p$ 。

3) 对矩阵 \mathbf{L} 进行谱分解, 求得低维空间的特征表示矩阵 \mathbf{F}_i (\mathbf{F}_i 为矩阵 \mathbf{L} 的前 d 个最小特征值所对应的特征向量构成的矩阵)。

4) 按 (3) 式更新权重系数 α_p 。

5) 如果 $N_{\text{Iter}} < N_{\text{Itermax}}$, 返回至第 2 步。

经过迭代更新, 得到融合后的特征表示矩阵 $\mathbf{F}_i \in R^{d \times (M+N)}$, \mathbf{F}_i 前 M 列和后 N 列分别为特征点 x_i 和 y_j 的特征矩阵, 记为 \mathbf{T}_i 和 \mathbf{T}_{j_t} , 则特征点 x_i 与特征点 y_j 的相似性度量可表示为

$$\omega_{ij} \equiv \text{sim}(x_i, y_j) = \exp\left(-\beta \prod_{t=1}^{|\mathbf{K}|} \|\mathbf{T}_i - \mathbf{T}_{j_t}\|\right), \quad (9)$$

式中 β 为平滑系数。

4 与几何相容性的结合

仅使用局部描述子很难获得理想的匹配结果,针对该问题,很多研究者讨论了局部描述子与几何相容性的结合^[14-16]。沿用该思路求解匹配问题,定义匹配目标函数为

$$C(\mathbf{X}, \mathbf{Y}, \varphi) = \gamma C_g(\mathbf{X}, \mathbf{Y}, \varphi) + C_s(\mathbf{X}, \mathbf{Y}, \varphi), \quad (10)$$

式中 γ 为权重系数, φ 为点集间的匹配对应关系。令 $C_s(\mathbf{X}, \mathbf{Y}, \varphi)$ 为利用谱描述子表示的匹配代价函数,由(9)式可得:

$$C_g(\mathbf{X}, \mathbf{Y}, \varphi) = \sum_{i=1}^M \sum_{i'=1}^M \|S(i, i') - S[\varphi(i), \varphi(i')]\|^2 + \sum_{j=1}^N \sum_{j'=1}^N \|S(j, j') - S[\varphi^{-1}(j), \varphi^{-1}(j')]\|^2. \quad (13)$$

若将 φ 表示成多元函数的形式,可用一个匹配概率矩阵 \mathbf{P} 来表示点集 \mathbf{X} 和 \mathbf{Y} 间的匹配对应关系,即若 x_i 与 y_j 匹配,则 $p_{ij} = 1$, 否则 $p_{ij} = 0$ 。可在矩阵 \mathbf{P} 中增加一行一列来处理不存在匹配点的情况:

$$\mathbf{P} = \begin{bmatrix} p_{11} & \cdots & p_{1N} & p_{1,ml} \\ \vdots & \ddots & \vdots & \vdots \\ p_{M1} & \cdots & p_{MN} & p_{M,ml} \\ p_{ml,1} & \cdots & p_{ml,N} & 0 \end{bmatrix}. \quad (14)$$

为满足一对一匹配约束条件,可对矩阵 \mathbf{P} 施加如下约束:

$$\begin{aligned} \sum_{j=1}^{N+1} p_{ij} &= 1, i = 1, 2, \dots, M, \\ \sum_{i=1}^{M+1} p_{ij} &= 1, j = 1, 2, \dots, N. \end{aligned} \quad (15)$$

使用高斯函数将(13)式改写成最大化的匹配代价形式。结合矩阵 \mathbf{P} , (10)式的目标函数可写成如下形式:

$$C(\mathbf{X}, \mathbf{Y}, \mathbf{P}) = 2\gamma \sum_{i=1}^M \sum_{S(i, i') \leq T} \sum_{j=1}^N \sum_{S(j, j') \leq T} p_{ij} p_{i'j'} \times \exp\left[-\frac{\xi(i, i', j, j')}{2\sigma^2}\right] + \sum_{i=1}^M \sum_{j=1}^N w_{ij} p_{ij}, \quad (16)$$

式中 $\xi(i, i', j, j') = \|S(i, i') - S(j, j')\|^2$ 表示点对 $(q_i, q_{i'}) \in \mathbf{X}$ 和 $(q_j, q_{j'}) \in \mathbf{Y}$ 间的序号差。由于 $p_{ij} \in (0, 1)$, 采用文献[16]中的方法, 将 p_{ij} 松弛至 $p_{ij} \in [0, 1]$, 使用概率松弛法迭代地求解(16)式的局部最优解。对于形如(16)式的目标函数, 其梯度 g_{ij} 为

$$g_{ij} = 4\gamma \sum_{S(i, i') \leq T} \sum_{S(j, j') \leq T} p_{i'j'} \exp\left[-\frac{\xi(i, i', j, j')}{2\sigma^2}\right] + w_{ij}. \quad (17)$$

利用概率松弛法, 第 r 次迭代后匹配概率的更新公

$$C_s(\mathbf{X}, \mathbf{Y}, \varphi) = \sum_{i=1}^M w_{i, \varphi(i)}. \quad (11)$$

$C_g(\mathbf{X}, \mathbf{Y}, \varphi)$ 表示由几何相容性得到的匹配代价。借鉴文献[11]中的方法, 以近似距离序表示几何相容性。特征点 $x'_i \in \mathbf{X}$ 相对于特征点 $x_i \in \mathbf{X}$ 的近似距离序定义为

$$S(x_i, x'_i) \equiv S(i, i') = [\|x_i - x'_i\| / d_x], \quad (12)$$

式中 d_x 表示特征点集内部所有点对间最近距离的平均值。利用近似距离序, $C_g(\mathbf{X}, \mathbf{Y}, \varphi)$ 可表示为

式为

$$p'_{ij} := p_{ij}^{r-1} g_{ij}^{r-1} / \sum_{j=1}^N p_{ij}^{r-1} g_{ij}^{r-1}. \quad (18)$$

利用(9)式的相似性表示作为松弛迭代的初始匹配概率, 在每轮迭代开始前, 为了满足(15)式的一对一匹配约束条件, 使用交替行列归一化的方法将矩阵 \mathbf{P} 转化为双随机矩阵^[17]的形式。经实验验证, 迭代更新 200 次已足够使矩阵 \mathbf{P} 收敛。在松弛迭代结束后, 为了获得更多的匹配对, 当 $p_{ij} > 0.6$ 时则认为点集 \mathbf{X} 中的第 i 个点和点集 \mathbf{Y} 中的第 j 个点存在匹配关系。 $p_{ml, j}$ 和 $p_{i, ml}$ 设置为 0.2。

5 实验及分析

分别在模拟数据和真实图像数据上测试此算法的性能。为了充分说明运用多种谱特征刻画点集结构信息的有效性, 将所给出的描述子与文献[11]中的特征表示方法进行比较(文献[11]仅用单一的拟拉普拉斯谱特征构造点集的局部结构描述子)。为简化起见, 依然将文献[11]的特征表示方法置于第4节所述的算法框架下进行比较, 即 $C_p(\mathbf{X}, \mathbf{Y}, \varphi)$ 由文献[11]中的特征表示方法计算获得, 其余参数设置均与该方法相同, 记该方法为 LG-QSC。此外, 为了说明特征融合上选用 MSE 算法的优势, 与经典的非负矩阵分解(NMF)特征融合算法^[18]以及简单拼接的方法进行对比, 比较方法为在所提出算法的谱融合步骤用 NMF 或简单拼接替代, 其余设置不变。另一对比算法为 Cour 算法^[10], 实验中采用了作者开放的源码。实验相关参数为: $\gamma = 0.2$, $\mathbf{K} = \{10, 13, 16\}$ 。

5.1 模拟数据

模拟数据点集的生成方式:模版点集 X 为单位平面内服从均匀分布的随机点集,大小为 40。不含位置噪声和出格点时的待匹配点集 Y 是由点集 X 经相似变换得来的,各相似变换参数为一定范围内的随机值,其中 x 轴与 y 轴方向的位移为 $[-1, 1]$, 旋转角度为 $[-180^\circ, 180^\circ]$ 。噪声通过在点集 X 的每个点上叠加一定的高斯噪声得来。其中高斯噪声的均值为零,方差以点集内点间最短平均距离为指

标。出格点是在模版点集中随机产生一定数量的点。实验分为两个部分,分别测试在噪声大小固定的情况下出格点对算法性能的影响及在出格点数目固定的情况下噪声对算法性能的影响。实验结果如图 2 所示。其中,图 2(a)和(b)的噪声水平分别为 0.1 和 0.2, (c)和(f)的出格点率为 0%, (d)和(g)的出格点率为 10%, (e)和(h)的出格点率为 20%。(a)~(h)纵坐标表示匹配精度,为 100 次蒙特卡罗实验的均值。

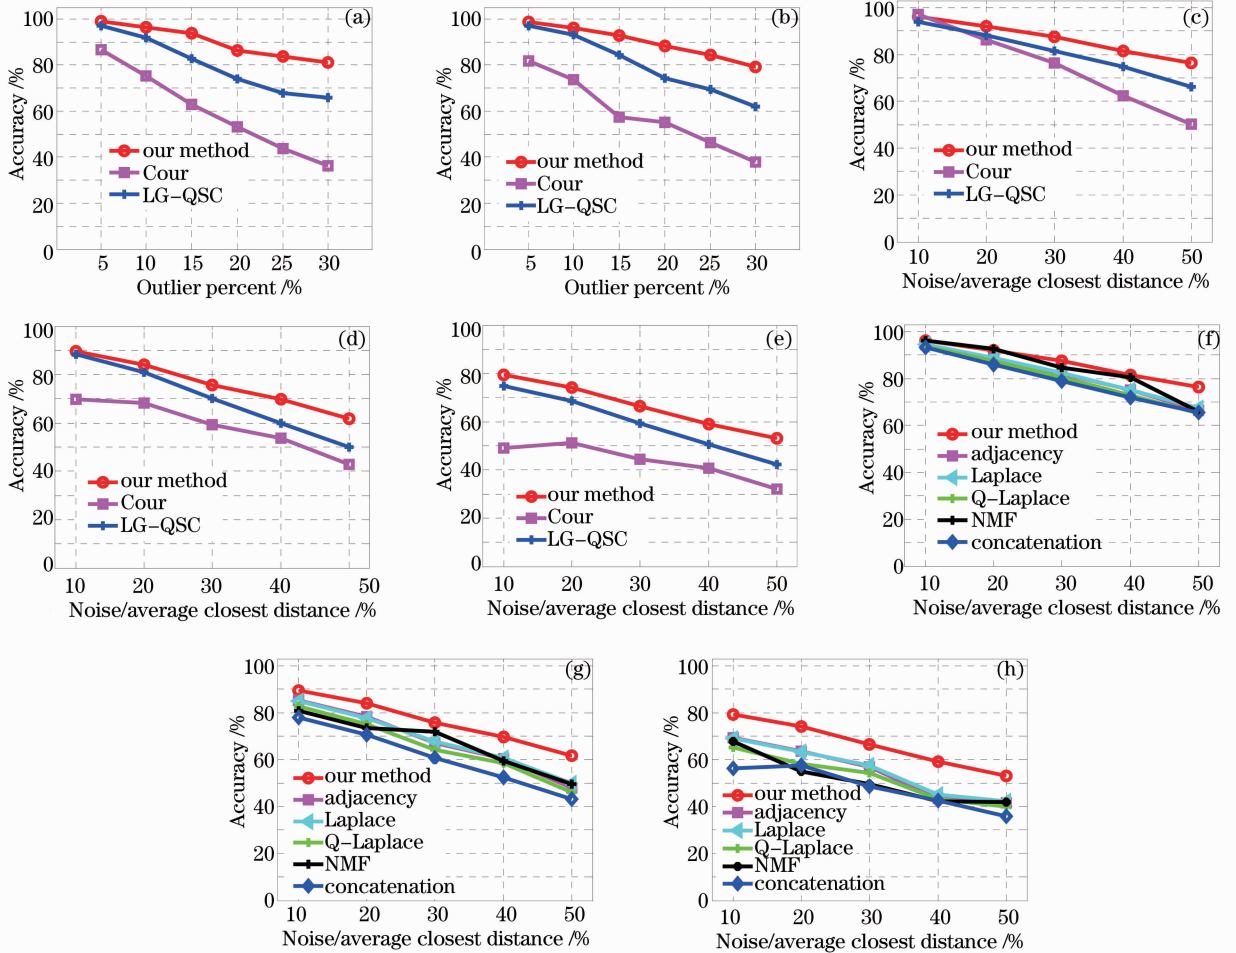


图 2 模拟数据对比实验。(a)~(e)不同算法;(f)~(h)不同特征表示方法

Fig. 2 Comparative experiments on simulated data. (a)~(e) various algorithms; (f)~(h) different feature representation methods

图 2(a)、(b)测试在噪声大小固定的情况下,各算法的匹配精度随出格点数目变化时的波动曲线,从图中可以看出,所用算法的匹配精度,相对于其他三种算法而言受出格点数目影响较小,即使在出格点数目较多的情况下也能给出相对较满意的结果。从图 2(c)、(e)对比实验可以看出,随着噪声的变大,各算法的匹配精度都呈现不同程度的下降趋势,但总体上而言,所提出的算法对噪声的稳健性要

优于其他三种算法。结合这三组模拟实验可以得出这样的结论:1)这里定义的基于多特征表示的结构描述子是行之有效的;2)算法提高了谱匹配算法抗噪和出格点的能力。图 2(d)、(f)反映的是基于 MSE 融合的多谱特征与单一的谱特征(即邻接谱、拉普拉斯谱和拟拉普拉斯谱)的对比实验。图中的 Concatenation 算法是指将(8)式的各种谱直接进行简单的拼接,NMF 是指采用非负矩阵分解融合谱

特征,目的是验证采用 MSE 算法对多谱特征处理的有效性。从图中可以看出,所提出的方法要优于单一的谱特征、简单拼接的特征以及非负矩阵分解融合得到的特征,甚至简单拼接的特征得到的匹配精度要低于单一的谱特征匹配,从而充分说明了基于 MSE 融合的多谱特征有效地实现了多特征间的优势互补。

算法采用 Matlab 2010 编程实现,在主频 2.60 GHz,内存 2.0 GB 的 PC,Windows XP 操作系统上,对于大小为 40 的点集,平均运行时间大约为 6 s。

5.2 真实图像实验

选择的真实图像来源于卡内基梅隆大学视觉与自主系统中心(CMU/VASC)图像数据库的房子序列,该数据库是一段反映视角变换情形下所拍摄的房屋模型的序列图像,共 111 帧。以第 0 帧作为基准图像,其他各帧待匹配图像从 111 帧图像中每间

隔 5 帧选取,共取 22 帧图像做测试。在每帧图像上先用 Harris 角点检测法检测出特征点的大致分布,为方便统计准确率,在每帧图像上选取 40 个在所有帧上均有对应关系的点作为匹配点集。所选取的 40 个特征点分布如图 3(a)所示。同时,为了能更精确地分析出格点对算法性能的影响,将实验分为三组:

1) 基准图像中的点集含有 40 个点,待匹配图像中的点集含有 40 个点,即两个点集都不含有出格点。

2) 基准图像中的点集含有 35 个点(随机剔除 5 个点),待匹配图像中的点集含有 40 个点,即待匹配点集中包含 5 个出格点。

3) 基准图像的点集和待匹配图像中的点集各含有 35 个点(两个点集各随机剔除 5 个点),即两个点集各含有 5 个出格点,实际对应特征点数为 30。




图 3 点集分布及部分匹配结果。(a)点集分布图;(b)~(d)匹配结果图,其中特征点数量分别为 40-40、35-40 和 35-35

Fig. 3 Distribution of feature point-sets and some matching results. (a) Distribution of point-sets; (b)~(d) illustration of matching results, where the numbers of feature points are 40-40, 35-40 and 35-35, respectively

在后两组实验中,由于出格点为随机选取,匹配正确率为 100 次实验的平均值。实验结果如图 4 所示,其中横坐标为帧差,纵坐标为匹配精度。图 4 (a)和(d)的特征点数量为 40-40,(b)和(e)的特征点数量为 35-40,(c)和(f)的特征点数量为 35-35。

从图 4(a)~(c)的真实图像实验数据可以看出,在不含出格点的情况下,随着图像视角的增大,谱融合算法和 LG-QSC 算法能给出较好的结果,而 Cour 算法的匹配精度下降较大。在含出格点的情况下,各算法的匹配精度都呈现不同程度的下降趋势,但总体而言,所提算法受图像视角变化和出格

点的影响相对较小,其稳健性要优于其他两种算法。这三组实验结果再次说明了定义的基于多特征表示的结构描述子是一种行之有效的特征表示方法。图 4(d)~(f)中不同特征的对比实验和模拟数据实验的结果基本相仿,从而进一步验证了基于 MSE 融合的多谱特征要优于单一的谱特征、非负矩阵分解融合得到的特征以及简单拼接的多谱特征。图 3(b)~(d)为定义的算法对第 10 帧和 70 帧进行匹配得到的匹配结果,其中特征点间的绿色连线为正确匹配对,红色连线为错误匹配对。

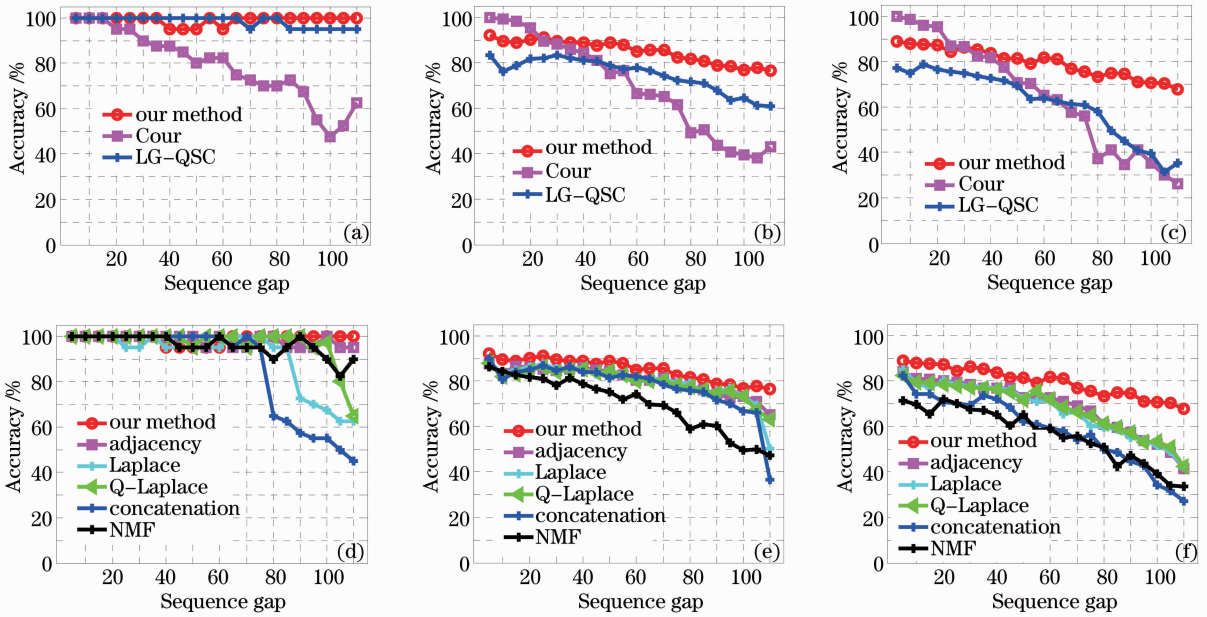


图4 真实图像数据对比实验。(a)~(c)不同算法；(d)~(f)不同特征表示方法

Fig. 4 Comparative experiments on real image data. (a)~(c) Various algorithms; (d)~(f) different feature representation methods

6 结 论

提出了一种基于多谱特征融合的点模式匹配算法,给出了一种利用各种特征的互补特性构造的局部结构描述子,结合几何相容性定义了匹配目标函数,并利用概率松弛进行求解。与当前现有算法的对比实验表明提出的算法对出格点和噪声具有更好的稳健性。

参 考 文 献

- Liu Guixi, Liu Dongmei, Liu Fengpeng, *et al.*. A robust image registration algorithm based on feature point matching [J]. *Acta Optica Sinica*, 2008, 28(3): 454–461.
刘贵喜, 刘冬梅, 刘凤鹏, 等. 一种稳健的特征点匹配算法[J]. *光学学报*, 2008, 28(3): 454–461.
- Hao Zhicheng, Zhu Ming. Serial image registration based on multiple restriction matching algorithm [J]. *Acta Optica Sinica*, 2010, 30(3): 702–707.
郝志成, 朱明. 基于多约束准则匹配算法的序列图像配准[J]. *光学学报*, 2010, 30(3): 702–707.
- Bao Wenxia, Liang Dong, Tang Jun. Matching algorithm based on probabilistic relaxation of spectral correlation [J]. *Acta Optica Sinica*, 2010, 30(3): 708–712.
鲍文霞, 梁栋, 唐俊. 一种基于谱相关性的概率松弛匹配算法[J]. *光学学报*, 2010, 30(3): 708–712.
- G L Scott, H C Longuet-Higgins. An algorithm for associating the features of two images [J]. *Proceeding of the Royal Society of London, Series B: Biological Sciences*, 1991, 244(1309): 21–26.
- L S Shapiro, J Brady. Feature-based correspondence: an eigenvector approach [J]. *Image and Vision Computing*, 1992, 10(5): 283–288.

- Wang Nian, Fan Yizheng, Wei Sui, *et al.*. Feature matching based on Laplacian spectra of graphs [J]. *Chinese J Image and Graphics*, 2006, 11(3): 332–336.
王年, 范益政, 韦穗, 等. 基于图的Laplace谱的特征匹配[J]. *中国图象图形学报*, 2006, 11(3): 332–336.
- M Carcassoni, E R Hancock. Spectral correspondence for point pattern matching [J]. *Pattern Recognition*, 2003, 36(1): 193–204.
- Tang Jun, Huang Huang, Liang Dong, *et al.*. Spectral correspondence for point pattern matching combined with analysis of geometric consistency [J]. *Acta Optica Sinica*, 2012, 32(7): 0715001.
唐俊, 黄煌, 梁栋, 等. 一种结合几何相容性分析的谱匹配算法[J]. *光学学报*, 2012, 32(7): 0715001.
- M Leordeanu, M Hebert. A spectral technique for correspondence problems using pairwise constraints [C]. *IEEE Conference on Computer Vision*, 2005, 2: 1482–1489.
- T Cour, P Srinivasan, J Shi. Balanced graph matching [C]. *Advances in Neural Information Processing Systems*, 2007, 313–320.
- Liang Dong, Zhu Ming, Tang Jun, *et al.*. A point pattern matching algorithm based on local relative shape context and Q-spectra [J]. *Acta Electronica Sinica*, 2012, 40(4): 636–641.
梁栋, 朱明, 唐俊, 等. 基于局部相对形状上下文与Q-谱的点模式匹配算法[J]. *电子学报*, 2012, 40(4): 636–641.
- R C Wilson, P Zhu. A study of graph spectra for comparing graphs and trees [J]. *Pattern Recognition*, 2008, 41(9): 2833–2841.
- T Xia, D Tao, T Mei, *et al.*. Multiview spectral embedding [J]. *IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics*, 2010, 40(6): 1438–1446.
- Tang Jun, Zhou Hongwei, Liang Dong, *et al.*. Approximate distance order based matching algorithm for images containing repetitive patterns [J]. *J Electronics & Information Technology*, 2012, 34(12): 3034–3039.
唐俊, 周洪伟, 梁栋, 等. 基于近似距离序的重复模式图像

- 匹配算法[J]. 电子与信息学报, 2012, 34(12): 3034-3039.
- 15 O Choi, I S Kweon. Robust feature point matching by preserving local geometric consistency [J]. Computer Vision and Image Understanding, 2009, 113(6): 726-742.
- 16 Y F Zheng, D Doermann. Robust point matching for non-rigid shapes by preserving local neighborhood structures [J]. IEEE Trans Pattern Analysis and Machine Intelligence, 2006, 28(4): 643-649.
- 17 R Sinkhorn. A relationship between arbitrary positive matrices and doubly stochastic matrices [J]. The Annals of Mathematical Statistics, 1964, 35(2): 876-879.
- 18 Miao Qiguang, Wang Baoshu. Multi-focus image fusion based on non-negative matrix factorization [J]. Acta Optica Sinica, 2005, 25(6): 755-759.
- 苗启广, 王宝树. 基于非负矩阵分解的多聚焦图像融合研究[J]. 光学学报, 2005, 25(6): 755-759.

栏目编辑: 韩 峰