

用于图匹配的子图学习算法

陈闯, 王亚*, 贾文武**

天津大学电气自动化与信息工程学院, 天津 300073

摘要 提出一种基于马尔科夫链蒙特卡罗(MCMC)框架的子图学习方法,该方法通过构建马尔科夫链实现子图在状态空间中的迭代,最终得到用于匹配的最优子图,以有效提高图匹配的精度,减少离散值的影响。在此过程中,所提方法可以在一对一的匹配约束下有效保存成对的匹配点,同时避免了离散值和畸变值的影响。实验分别在合成图像数据集、真实图像数据集、3D 模型数据集上展开,实验结果证明了所提方法在图匹配过程中的优越性。

关键词 图像处理; 图匹配; 机器学习; 马尔科夫链蒙特卡罗; 离散值

中图分类号 TP37 文献标志码 A

doi: 10.3788/LOP57.061003

A Subgraph Learning Method for Graph Matching

Chen Chuang, Wang Ya*, Jia Wenwu**

School of Electrical and Information Engineering, Tianjin University, Tianjin 300073, China

Abstract In this study, we propose a subgraph learning method based on the Markov chain Monte Carlo framework. Further, we obtain an iterative process with respect to the subgraphs in the state space by constructing a Markov chain and optimal subgraphs for matching to effectively improve the graph matching precision and reduce the impact of the discrete values. During this process, the proposed method can effectively save the pairs of matching points under one-to-one matching constraints, avoiding the influence of the discrete and distortion values. Furthermore, the experiments are conducted with respect to the synthetic image dataset, real image dataset, and three-dimensional model dataset. The experimental results demonstrate that the proposed method is superior in the graph matching process.

Key words image processing; graph matching; machine learning; Markov chain Monte Carlo; discrete value

OCIS codes 100.4994; 100.4996; 100.3008

1 引言

图匹配^[1]作为一种通用且有效的方法被广泛应用于各学科领域,如图像检索^[2]、目标识别^[3]、目标跟踪^[4]等领域。图匹配将位于不同子空间的两组特征点定义为集合,每个集合可以被视为一个图,被表征的图由节点和边缘两部分组成,节点表示特征点,边缘表示相邻特征点之间的关系。图匹配旨在发现每个特征点在另一个子空间中的对应点,虽然科研人员已对此进行了大量的研究,但由于视觉特征表示要有较高的辨识性,重要点的精确定位难度大,视点变化导致的成对点之间的相关性变化,离散值的

影响较大等,图匹配的研究应用仍然面临较大的挑战。

近年来,图匹配问题被普遍描述为整数二次规划(IQP)问题^[5],IQP 在匹配过程中考虑图的节点和边缘信息,只允许将简单的点乘或平方误差作为相似度的度量^[6]。然而 IQP 在匹配过程中也存在一个关键的问题:由于 IQP 解决方案的前提是具有一定数量的节点匹配,因此该解决方案可能包含许多离散值,解决方案中包含的离散值使目标函数的判断精确度下降,当离散值的数量很多时,最终的匹配对会包含许多错误的匹配结果,大量的离散值必定影响目标函数的优化并产生一系列的错误匹

收稿日期: 2019-05-01; 修回日期: 2019-05-13; 录用日期: 2019-08-27

基金项目: 国家自然科学基金(61472275, 61170239, 61303208, 61502337)

* E-mail: wangyares@outlook.com; ** E-mail: 975045265@qq.com

配对。

目前大多数用于解决图匹配问题的算法都是基于 IQP 公式的图匹配算法。Gori 等^[7]提出了基于模型的随机游动方法,该方法可以在节点层面增强图形拓扑特征;Cho 等^[8]基于 IQP 公式,利用随机游动方法求解图匹配问题;Zaslavskiy 等^[9]提出一种用于标记加权图匹配问题的凹凸规划方法,该方法可以很容易地将具有图标签相似性的信息集成到优化问题中。

上述方法专注于一对一的匹配问题,忽略了匹配结果的精度和离散值的负面影响,子图匹配是一种可以在匹配过程中去除离散值、保存匹配点并且可以提高匹配精确率(匹配结果中正确匹配的个数在所有匹配个数中的占比)和召回率(匹配结果中正确匹配的个数在 groundtruth 中的占比)^[10]的方法。Suh 等^[11]提出一种新的子图匹配方法,他们使用一种偏向于稀疏解值的附加约束,有效消除了离散值的影响;Dahm 等^[12]提出一种在子图同构检测期间能够最大限度地减少搜索状态数量的方法,该方法能够从一组邻域图中计算得到高级拓扑节点特征,计算得到的高级拓扑节点特征表示在处理图匹配问题中优于现有的特征表示。

本文提出一种新颖而简单的算法,该算法在 IQP 公式的基础上添加两个惩罚项来约束离散值,进而有效地学习子图来表示原始图的结构信息。在优化过程中,本文提出一种基于马尔科夫链蒙特卡罗(MCMC)框架^[13]的子图学习方法,该方法利用一个有效的状态转移函数来构造马尔科夫链,初始化的子图经过所构造的马尔科夫链中的状态转换,并结合 IQP 公式,可得到用于匹配的最优子图。实验结果表明,本文所提出的解决方案可显著提高存在离散值和变化噪声问题的图匹配的召回率和精确率。

2 方法

2.1 图匹配的定义

图匹配问题需要考虑不同图之间的一对一匹配结果,假设当前有两个图 $G_1 = \{V_1, E_1, A_1^v, A_1^e\}$ 和 $G_2 = \{V_2, E_2, A_2^v, A_2^e\}$, 其中 V 、 E 、 A^v 、 A^e 分别表示节点、边缘、节点属性和边缘属性。图匹配的目标是在所有可能的对应关系中找到 G_1 和 G_2 的节点对应的子集,采用 $y \in \{0, 1\}^{n_1 \times n_2}$ 表示匹配结果,其中 n_1 和 n_2 分别表示 G_1 和 G_2 中的节点数,如果选择第 i 个匹配,则 y_i 为 1,否则为 0,关联矩阵 M 由 G_1

和 G_2 中对应边和节点之间的关系相似性值组成。

目前已经有许多方法利用 IQP 公式来处理图匹配问题, IQP 公式的定义为

$$\begin{cases} y^* = \arg \max_y (y^T M y) \\ \text{s.t. } y \in \{0, 1\}^{n_1 \times n_2} \\ \sum_j y_{ij} \leq 1, \sum_i y_{ij} \leq 1 \end{cases}, \quad (1)$$

式中: y^* 为目标函数; y_{ij} 和 y_{ji} 分别为图 G_1 的第 i 个节点和图 G_2 的第 j 个节点是否匹配,若匹配则为 1,不匹配则为 0。 $\sum_j y_{ij} \leq 1$ 和 $\sum_i y_{ij} \leq 1$ 增强了节点之间一对一的约束,因此(1)式可以有效地处理一些简单的匹配问题,但由于 IQP 解决方案的前提是具有一定数量的节点匹配,所以会引入很多离散节点,导致匹配的精确性降低,因此很难避免离散值干扰。

2.2 图匹配的优化

为了处理离散值问题,本研究从原始图中选择一个没有离散值的子图,同时该子图也可以表示原始图的结构信息。在图匹配的过程中,这种设计可以有效地保证匹配的精确性和召回率。因此,图匹配的目标函数可表示为

$$\begin{cases} y^* = \arg \max_y [y^T(x) M y(x)] - \\ \lambda_1 \|y\|_0 - \lambda_2 x^T W x \\ \text{s.t. } y \in \{0, 1\}^{n_1 \times n_2}, x \in \{0, 1\}^{n_1} \\ \sum_j y_{ij} \leq 1, \sum_i y_{ij} \leq 1 \end{cases}, \quad (2)$$

式中: W 为 G_1 中节点之间的相似性矩阵; $X = \{x | x \in \{0, 1\}^{n_1}\}$; n_1 是 G_1 的节点数。函数 $y(\cdot)$ 的定义为

$$\begin{cases} y(x) = \arg \max_y (y^T M y) \\ \text{s.t. } y \in \{0, 1\}^{n_1 \times n_2} \\ \sum_j y_{ij} \leq 1, \sum_i y_{ij} \leq 1 \end{cases}. \quad (3)$$

图 G'_1 和 G_2 之间的图匹配可以应用传统 IQP 优化方法^[14] [(3)式]进行处理,其中 G'_1 是 G_1 的子图。

(2)式可用于从原始图 G_1 中学习子图 G'_1 以进行匹配,如果在子图 G'_1 中选择第 i 个节点,则 $x_i = 1$,否则 $x_i = 0$ 。 y 表示 G'_1 和 G_1 之间节点的成对匹配关系,并利用 $\|y\|_0$ 来约束子图的大小。由于子图表征图 G_1 的结构信息,为此应削弱不同节点之间的相关性, $x^T W x$ 用于约束子图 G'_1 中节点之间的弱相关性, λ_1 和 λ_2 分别用于控制惩罚因子的权重。

2.3 基于 MCMC 框架的子图学习方法

本文应用 MCMC 框架来解决优化过程中存在的问题。MCMC 的基本思想是在状态空间 \mathbf{X} 上构造马尔科夫链, \mathbf{X} 表示 \mathbf{G}_1 的子图状态空间。本文方法需要在 \mathbf{X} 上定义目标概率分布函数 $P(x)$,

$$P(x) = \exp[\mathbf{y}^T(x)\mathbf{M}\mathbf{y}(x) - \lambda_1 \|\mathbf{y}\|_0 - \lambda_2 \mathbf{x}^T \mathbf{W}\mathbf{x}]. \quad (4)$$

马尔科夫链中的状态转移旨在根据(3)式在状态空间 \mathbf{X} 中选出 \mathbf{G}_2 的最佳匹配子图 \mathbf{x} 。

马尔科夫链由经典的 Metropolis-Hastings 采样方法生成。本文采用了两种不同的转移方案,即随机转移方案和状态转移方案,随机转移方案的定义为

$$q_{\text{rand}}(\mathbf{x} \rightarrow \mathbf{x}') = \begin{cases} 1/n_1, & \text{if } \|\mathbf{x}' - \mathbf{x}\|_1 = 1 \\ 0, & \text{otherwise} \end{cases}. \quad (5)$$

由(5)式可知:一种状态转换为另一状态的概率为 $1/n_1$, 这表明状态转移在状态空间内较为活跃。

本文基于子图与原始图模型之间的相似性设计了状态转移方案,重构子图应具有稳定的结构与原始图的较高相似性,因此状态转移方案可以定义为

$$q_{\text{data}}(\mathbf{x} \rightarrow \mathbf{x}') = \begin{cases} \frac{1}{Z} \exp\left(-\frac{|\mathbf{x}'^T \mathbf{W}\mathbf{x}' - \mathbf{x}^T \mathbf{W}\mathbf{x}|}{\tau}\right), & \text{if } \|\mathbf{x}' - \mathbf{x}\|_1 = 1 \\ 0, & \text{otherwise} \end{cases}, \quad (6)$$

式中: Z 和 τ 均为归一化常数。状态转移方案根据(6)式的概率分布对节点进行采样,这就可以将采样范围约束在一个小区域内,从而快速找到最佳匹配结果。

接受率是指在状态空间中子图从一种状态转换成另一种状态后被接受的可能性,接受率的定义为

$$a(\mathbf{x} \rightarrow \mathbf{x}') = \min\left\{\frac{p(\mathbf{x}')q(\mathbf{x}' \rightarrow \mathbf{x})}{p(\mathbf{x})q(\mathbf{x} \rightarrow \mathbf{x}')}, 1\right\}. \quad (7)$$

$q(\cdot)$ 根据方案类型可定义为(5)式或者(6)式,整体算法如图 1 所示。

3 实验

本节包含四个部分:在第一部分中,分析了不同参数 λ_1 和 λ_2 对匹配效果的影响。在第二部分中,在人工合成图数据集上通过改变离散点的个数、变化噪声的大小和不同的边缘密度来评估本文提出的图匹配方法。在这一部分中,将提出的方法与几种常用的图匹配方法基于人工合成图进行比较,常用

```

Input: Affinity matrix  $\mathbf{M}$  and Weight of node  $\mathbf{W}$ 
Output: Matching  $\mathbf{y}^*$  and subgraph  $\mathbf{x}^*$ 
Initialization subgraph  $\mathbf{x}$  by SM[23], iteration number  $N$ 
while  $n < N$  do
    Calculated proposal distribution  $q(\mathbf{x} \rightarrow \mathbf{x}')$  by Eq.5
    or Eq.6
    Sample  $\mathbf{x}'$  according to  $q(\mathbf{x} \rightarrow \mathbf{x}')$ 
    Update the  $\mathbf{W}$  by[26]
    Calculated acceptance ratio  $a(\mathbf{x} \rightarrow \mathbf{x}')$ 
    if  $\text{rand}() < a(\mathbf{x} \rightarrow \mathbf{x}')$  then
        Calculated  $p(\mathbf{x}')$ 
        if  $p(\mathbf{x}') > p(\mathbf{x})$  then
             $\mathbf{y}^* \leftarrow \mathbf{y}(\mathbf{x}')$ 
             $\mathbf{x}^* \leftarrow \mathbf{x}'$ 
return  $\mathbf{x}^*, \mathbf{y}^*$ 

```

图 1 基于 MCMC 的子图匹配算法

Fig. 1 Sub-graph matching algorithm based on MCMC

的图匹配方法包括 SM、HGM^[17]、RRWM^[8]、RRWHM^[18]、TM^[19]、FGM^[20] 和 IPFP^[21]。考虑到准确性和可信度等因素,本文使用上述图匹配方法基于 MATLAB 软件实现开源代码和指定的参数,并在单核计算机上进行测试(CPU 的频率为 3.5 GHz;RAM 为 12 GB)。在人工合成图实验中,所有方法使用相同的合成图,取 30 次随机实验的精确率以及召回率的平均值作为定量分析结果。在第三部分中,基于真实图像数据集将提出的方法与三种流行的图匹配方法即 RRWM、SM 和 IPFP 进行比较。在最后一部分中,将所提方法与当前主流的图匹配方法同时应用于基于视图的三维模型检索并对检索结果进行分析。

3.1 参数对子图学习方法的影响

为了评估当 λ_1 和 λ_2 变化时算法的鲁棒性,将 σ 定义为 0.2 并且 n_{out} 固定为 10,召回率随 λ_1 和 λ_2 的变化趋势如图 2 所示,精确率随 λ_1 和 λ_2 的变化趋势如图 3 所示。由图 2 和图 3 可知,当参数 λ_1 为 1.5, λ_2 为 1 时,精确率和召回率具有最佳匹配结果。

3.2 合成图数据集评估

按照文献[18]的实验方案,本实验基于合成图数据集对本文方法进行评估。每个实验构建两个图,其中图 \mathbf{G}^b 包含 $n^b = n_{\text{in}} + n_{\text{out}}^b$ 个节点,图 \mathbf{G}^q 包含 $n^q = n_{\text{in}} + n_{\text{out}}^q$ 个节点, n_{in} 为被选择用于匹配的目标节点数量, n_{out}^b 和 n_{out}^q 分别表示两个图中未用于匹配的离散节点数量。实验使用随机边缘密度 ρ 生成参考图 \mathbf{G}^b , 其中每个边缘 e_{st}^b 被赋予在 0 到 1 内呈均




图2 召回率变化曲线
Fig. 2 Recall rate curves




图3 精确率变化曲线
Fig. 3 Precision curves

匀分布的随机属性 a_{st}^l 。实验通过在 G^p 中目标节点之间的边缘属性上添加噪声来创建图 G^q : $a_{ab}^q = a_{st}^l + \sigma$, 其中变形噪声 σ 由高斯函数 $N(0, \sigma^2)$ 生成, G^q 中所有连接中至少一个离散节点的其他边缘按照 G^p 中产生边缘的方式随机生成。因此两个图 G^p 和 G^q 都包含一个具有 n_{in} 个节点的公共扰动子图。





图4 离散实验的召回率和精确率。(a)离散值对召回率的影响;(b)离散值对精确率的影响

Fig. 4 Recall rate and precision in the outlier experiments. (a) Effect of discrete values on recall rate; (b) effect of discrete values on precision

3.3 真实图像数据集评估

本节基于真实图像数据集 Caltech+MSRC^[18] 实现了 SGM 方法。本实验构建了一个由 30 对图像对组成的数据集, 并使用 MSER 检测器和 SIFT 描述符基于构建的数据集生成候选对应关系, 其中 30 对图像对来自数据集 Caltech+MSRC。本实验

本实验有三个自变量: 离散值 n_{out}^p 或 n_{out}^q , 变形噪声 σ 和边缘密度 ρ , 因此本文分别进行三次实验来评估它们对性能的影响, 每次实验生成 30 个不同的图对, 并计算了每次实验的平均召回率和平均精确率作为评估指标。第一次实验将离散值从 0 调整到 20, 步长为 2, 同时固定目标节点数 $n_{in} = 20$, 变形噪声 $\sigma = 0.5$, 实验结果如图 4 所示。第二次实验将变形噪声 σ 从 0 调整到 0.2, 步长为 0.025, 同时固定目标节点数 $n_{in} = 20$, 离散值 $n_{out}^p = n_{out}^q = 5$, 实验结果如图 5 所示。第三次实验将边缘密度 ρ 从 0 调整到 2, 步长为 0.2, 同时固定目标节点数 $n_{in} = 20$, 离散值 $n_{out}^p = n_{out}^q = 0$, 实验结果如图 6 所示。

实验结果表明: 本文所提出的子图学习方法 (SGM) 在精确率和召回率方面均优于其他常用方法, 并且在变化噪声和离散值同时存在的情况下, SGM 方法具有较好的鲁棒性。本实验中, SM、FGMU、FGMD、IPFP、RRWM 和 RRWHM 等对比方法均利用 IQP 公式来处理图匹配问题, 但这些方法只关注图与图之间成对的匹配, 忽略了离散值的影响。FGMU 和 FGMD 方法在图匹配中的精确率和召回率与 SGM 方法近似相等, 但是 FGM 方法的运行时间相比 SGM 方法要长 100 多倍, 它不适合处理检索、匹配、识别等方面的计算机视觉问题。HGM 和 TM 方法一般应用于高阶图匹配, 它们需要基于节点计算高阶特征, 因此 HGM 和 TM 方法容易受到离散值的影响, 相应的实验结果也证明了这一结论。

通过计算图像对中 128-d SIFT 描述符之间的距离来确定是否应该收集候选匹配对, 如果单个匹配对的距离小于松散阈值 $\delta = 0.6$, 则收集该候选匹配对。在实验过程中, 本实验标注了所有候选对中每个图像对的 groundtruth, 计算了 SGM 方法的精确率和相对客观评分, 并将 SGM 方法与几种代表性

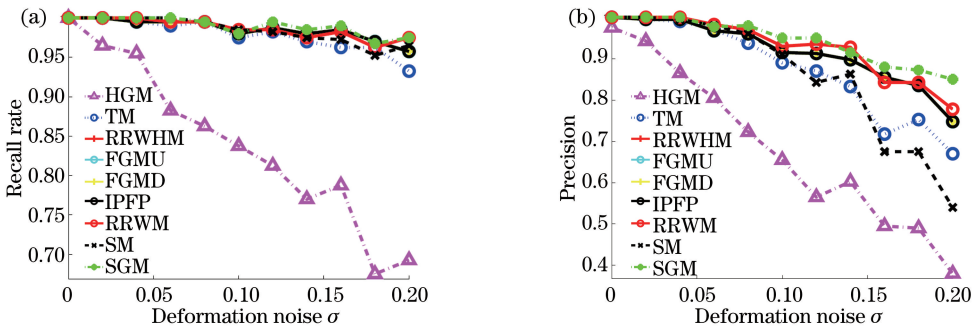


图 5 变形噪声实验的召回率和精度。(a)变形噪声对召回率的影响;(b)变形噪声对精确率的影响

Fig. 5 Recall rate and precision in the deformation noise experiments. (a) Effect of deformation noise on recall rate; (b) effect of deformation noise on precision

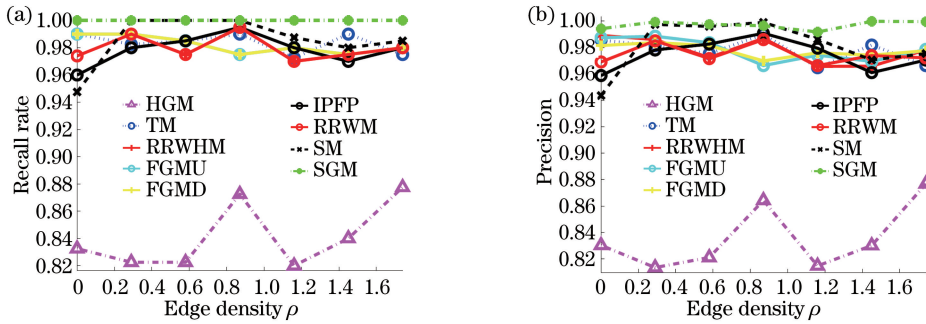


图 6 不同边缘密度实验的召回率和精确率。(a)边缘密度对召回率的影响;(b)边缘密度对精确率的影响

Fig. 6 Recall rate and precision in the experiments with different edge densities. (a) Effect of edge density on recall rate; (b) effect of edge density on precision

方法 (RRWN、SM、SMAC^[22]、GAGM^[23]、IPFP) 进行比较,实验结果如表 1 所示,一些具有代表性的例子如图 7~9 所示,其中黄线表示匹配结果中的正确匹配,黑线表示匹配结果中未能正确匹配节点的 groundtruth。表 1 的对比实验结果表明:SGM 方法在召回率和精确率方面均优于其他方法,实验结果充分证明了该方法的优越性。

表 1 不同方法在 Caltech+MSRC 上的召回率和精确率

Table 1 Recall rate and precision of different methods on Caltech+MSRC

Method	Recall rate	Precision
SGM	0.7510	0.749
RRWM	0.6401	0.632
SM	0.5208	0.521
IPFP	0.4120	0.402
SMAC	0.3974	0.388
GAGM	0.5874	0.571

3.4 3D 模型数据集评估

本节基于 3D 模型数据集 MV-RED1 上实现了 SGM 方法。MV-RED 数据集由 Kinect 摄像机记录,包含 505 个现实世界中的模型对象,每个对象包含来自 3 个视角的 73 张 RGB 图像。本实验首先利

用每个 2D 图像的视觉信息来构建单个 3D 模型表示的图模型,然后利用所提出的 SGM 方法计算不同 3D 模型之间的正确匹配率,而正确匹配率可以视为不同 3D 模型之间的相似性度量,最后利用相似度进行模型检索。

由于每个 3D 模型由 73 个视图组成,每个视图由 73 个节点组成,因此 505 个 3D 模型基于节点的匹配实验比之前任何实验都复杂得多;光照、视点等的变化将直接导致随机噪声和离散值的产生,随机噪声和离散值的产生使鲁棒特征的提取更加困难。因此,基于图匹配实现三维模型检索更具挑战性。

为了评估 3D 模型检索的性能,采用 7 种已广泛应用于信息检索领域的评价标准^[16]——*P-R* 曲线、*NN*、*FT*、*ST*、*F-measure*、*DCG* 和 *ANMRR* 作为检索性能的评估参数。

1) *P-R* 曲线。假设检索模型在模型库中的模型类别为 *S*,数量为 P_s ,实际检索出 N 个最相似结果。其中精确率 P 表示在 N 个检索结果中与 *S* 为同类型的模型所占的比例,召回率 R 表示检索结果与 *S* 为类型相同的模型在 P_s 中所占的比例。在判别检索结果中的模型是否归属于 *S* 类时会存在一个




图 7 Caltech+MSRC 上的摩托车图形匹配样本。(a) 基于 SGM 的匹配样本(正确匹配率为 12/54);(b) 基于 RRWM 的匹配样本(正确匹配率为 11/67);(c) 基于 IPFP 的匹配样本(正确匹配率为 7/67);(d) 基于 SM 的匹配样本(正确匹配率为 9/67)

Fig. 7 Samples of graph matching for motorbike on Caltech + MSRC. (a) SGM-based matching sample (correct matching rate is 12/54); (b) RRWM-based matching sample (correct matching rate is 11/67); (c) IPFP-based matching sample (correct matching rate is 7/67); (d) SM-based matching sample (correct matching rate is 9/67)




图 8 Caltech+MSRC 帽子图形匹配样本。(a) 基于 SGM 的匹配样本(正确匹配率为 4/7);(b) 基于 RRWM 的匹配样本(正确匹配率为 4/9);(c) 基于 IPFP 的匹配样本(正确匹配率为 2/9);(d) 基于 SM 的匹配样本(正确匹配率为 2/9)

Fig. 8 Samples of graph matching for cap on Caltech + MSRC. (a) SGM-based matching sample (correct matching rate is 4/7); (b) RRWM-based matching sample (correct matching rate is 4/9); (c) IPFP-based matching sample (correct matching rate is 2/9); (d) SM-based matching sample (correct matching rate is 2/9)

判别阈值, $P-R$ 曲线是模型检索结果的精确率和召回率随模型判别阈值降低的变化趋势。

2) NN。NN 是指在检索结果中检索出的最相似模型的精确率。

3) FT。FT 表示 $N = P_s - 1$ 时的召回率。

4) ST。ST 表示当 $K = 2(P_s - 1)$ 时的召回率。

5) F -measure。 F -measure 是精确率和召回率的加权调和平均,其定义为

$$F - R_{\text{measure}} = \frac{2PR}{P + R} \quad (8)$$

6) DCG。DCG 是指所有正确模型位置信息标

准化后的加权和,其位置越靠前,则权重越大。首先将检索结果列表转化为向量 G , 该向量的元素 $G_i = 1$ 表示第 i 个位置为正确结果, 否则 $G_i = 0$ 。则 DCG 的计算公式为

$$R_{\text{DCG}_i} = \begin{cases} G_i, & i = 1 \\ R_{\text{DCG}_{i-1}} + \frac{G_i}{\log_2 i}, & \text{otherwise} \end{cases} \quad (9)$$




图9 Caltech+MSRC 汽车图形匹配样本。(a)基于 SGM 的匹配样本(正确匹配率为 16/30);(b)基于 RRWM 的匹配样本(正确匹配率为 12/36);(c)基于 IPFP 的匹配样本(正确匹配率为 4/36);(d)基于 SM 的匹配样本(正确匹配率为 4/36)

Fig. 9 Samples of graph matching for car on Caltech+MSRC. (a) SGM-based matching sample (correct matching rate is 16/30); (b) RRWM-based matching sample (correct matching rate is 12/36); (c) IPFP-based matching sample (correct matching rate is 4/36); (d) SM-based matching sample (correct matching rate is 4/36)

然后将其标准化,可得

$$R_{\text{DCG}} = \frac{R_{\text{DCG}_n}}{1 + \sum_{j=2}^C \frac{R_{\text{DCG}_n}}{\log_2 j}}, \quad (10)$$

式中: C 为模型总数。

7) ANMRR。ANMRR 是指平均归一化检索秩^[24],反映检索结果中正确模型的排序性能。

本文选择了一些目前比较先进的方法^[25]进行对比。此外,选取了光谱匹配(SM)、重加权随机游走匹配(RRWM)、加权二分图匹配(WBGM)^[26]等常用的图匹配方法进行比较。检索结果如图 10 所示,其中图 10(a)所示为 MV-RED 数据集的 P - R

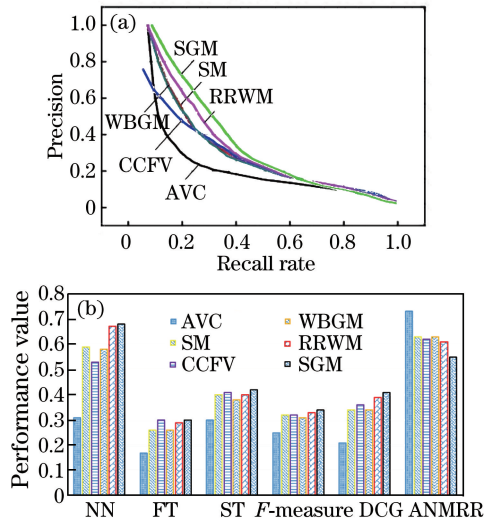


图 10 MV-RED 数据集中基于视图的 3D 模型检索实验结果。(a) P - R 曲线;(b)性能指标

Fig. 10 Results of view-based 3D model retrieval experiments in MV-RED data set. (a) P - R curves; (b) performance

曲线,图 10(b)所示为各方法的性能指标。从图 10 可以看出:1)CCFV^[25]和 AVC^[27]中利用概率模型计算相似性,这两种方法考虑了 2D 图像的特征分布,并应用统计模型来表示 3D 模型。CCFV 中应用高斯模型来模拟对象的特征分布,因此 CCFV 可以利用更多数据进行模型学习,进而获得更强的鲁棒性。AVC 中应用贝叶斯模型基于 2D 图像的视觉信息计算不同 3D 模型之间的相似度。这些方法都只考虑了 2D 图像的视觉属性而忽略了 3D 模型的结构信息,因此最终的检索结果比本文方法的效果差。2)选取部分经典的图形匹配方法作为比较方法,其中 WBGM 与二分图匹配方法类似,两者的不同之处在于 WBGM 中引入了节点的权重以提高匹配的准确性,但是 WBGM 没有考虑图的边缘信息,WBGM 可以看作是一元属性的图匹配,最终的检索结果比本文方法差。3)RRWM 和 SM 是基于 IQP 公式的经典图形匹配方法。视点、照明等变化会导致一个模型的不同视图的视觉外观发生显著变化,并进一步引入噪声和离散值,噪声和离散值可能进一步导致更复杂的边缘属性。因此提取鲁棒图像特征进行视觉表征的难度非常大,不稳定的一元和成对属性将导致图匹配性能变差。相对而言,本文方法可以有效地减少离散值的影响,利用学习到的子图来表示图模型的结构信息。综上所述,SGM 方法的性能优于所有比较方法。

4 结 论

提出一种新的子图学习方法来处理经典的图匹配问题。在此过程中,提出一种新的 MCMC 采样方法来优化目标函数,优化后的方法可以有效降低离散值的影响,并在匹配过程中保存匹配点。实验结果表明:本文方法在合成图匹配和特征对应问题上均优于其他方法,并且在噪声和离散值存在的情况下具有较好的鲁棒性。

参 考 文 献

- [1] Zhang X, Jin Y X, Xue D. Image matching algorithm based on SICA-SIFT and particle swarm optimization [J]. *Laser & Optoelectronics Progress*, 2017, 54(9): 091002.
张鑫, 靳雁霞, 薛丹. SICA-SIFT 和粒子群优化的图像匹配算法 [J]. *激光与光电子学进展*, 2017, 54(9): 091002.
- [2] Peng Y F, Wu H, Zi L L. Image retrieval based on hash method and generative adversarial networks [J]. *Laser & Optoelectronics Progress*, 2018, 55(10): 101002.
彭晏飞, 武宏, 訾玲玲. 基于哈希算法及生成对抗网络的图像检索 [J]. *激光与光电子学进展*, 2018, 55(10): 101002.
- [3] Grimson W E L, Huttenlocher D P. Object recognition by computer: the role of geometric constraints [M]. America: MIT Press, 1990: 350-504.
- [4] He X D, Zhou S Z. Fast scale adaptive kernel correlation filtering algorithm for target tracking [J]. *Laser & Optoelectronics Progress*, 2018, 55(12): 121501.
何雪东, 周盛宗. 快速尺度自适应核相关滤波目标跟踪算法 [J]. *激光与光电子学进展*, 2018, 55(12): 121501.
- [5] Serratos F, Cortés X. Interactive graph-matching using active query strategies [J]. *Pattern Recognition*, 2015, 48(4): 1364-1373.
- [6] Egozi A, Keller Y, Guterman H. A probabilistic approach to spectral graph matching [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(1): 18-27.
- [7] Gori M, Maggini M, Sarti L. Exact and approximate graph matching using random walks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(7): 1100-1111.
- [8] Cho M, Lee J, Lee K M. Reweighted random walks for graph matching [M] // Daniilidis K, Maragos P, Paragios N. *Computer vision-ECCV 2010. Lecture notes in computer science*. Berlin, Heidelberg: Springer, 2010, 6315: 492-505.
- [9] Zaslavskiy M, Bach F, Vert J P. A path following algorithm for the graph matching problem [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(12): 2227-2242.
- [10] Tao S Q, Wang S T. An algorithm for weighted subgraph matching based on gradient flows [J]. *Information Sciences*, 2016, 340/341: 104-121.
- [11] Suh Y, Adamczewski K, Mu Lee K. Subgraph matching using compactness prior for robust feature correspondence [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 5070-5078.
- [12] Dahm N, Bunke H, Caelli T, et al. Efficient subgraph matching using topological node feature constraints [J]. *Pattern Recognition*, 2015, 48(2): 317-330.
- [13] Lee J, Cho M, Lee K M. A graph matching algorithm using data-driven Markov chain Monte Carlo sampling [C] // 2010 20th International Conference on Pattern Recognition, August 23-26, 2010, Istanbul, Turkey. New York: IEEE, 2010: 2816-2819.
- [14] Nie W Z, Liu A A, Gao Z, et al. Clique-graph matching by preserving global & local structure [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 4503-4510.
- [15] Leordeanu M, Hebert M. A spectral technique for correspondence problems using pairwise constraints [C] // Tenth IEEE International Conference on Computer Vision (ICCV'05), October 17-21, 2005, Beijing, China. New York: IEEE, 2005, 1: 1482-1489.
- [16] Liu A A, Wang Z Y, Nie W Z, et al. Graph-based characteristic view set extraction and matching for 3D model retrieval [J]. *Information Sciences*, 2015, 320: 429-442.
- [17] Zass R, Shashua A. Probabilistic graph and hypergraph matching [C] // IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2008, Anchorage, AK, USA. New York:

- IEEE, 2008: 10139805.
- [18] Lee J, Cho M, Lee K M. Hyper-graph matching via reweighted random walks [C] // 2011 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2011, Providence, RI, USA. New York: IEEE, 2011: 1633-1640.
- [19] Duchenne O, Bach F, Kweon I S, et al. A tensor-based algorithm for high-order graph matching [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2383-2395.
- [20] Zhou F, de la Torre F. Factorized graph matching [C] // 2012 IEEE Conference on Computer Vision and Pattern Recognition, June 16-21, 2012, Providence, RI, USA. New York: IEEE, 2012: 127-134.
- [21] Leordeanu M, Hebert M, Sukthankar R. An integer projected fixed point method for graph matching and map inference [C] // Advances in Neural Information Processing Systems. December 7-10, 2009, Vancouver, British Columbia, Canada. Canada: NIPS, 2009: 1114-1122.
- [22] Cour T, Srinivasan P, Shi J B. Balanced graph matching [C] // Advances in Neural Information Processing Systems, December 4-7, 2006, Vancouver, British Columbia, Canada. Canada: NIPS, 2007: 313-320.
- [23] Gold S, Rangarajan A. A graduated assignment algorithm for graph matching [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996, 18(4): 377-388.
- [24] Chun Y D, Kim N C, Jang I H. Content-based image retrieval using multiresolution color and texture features [J]. IEEE Transactions on Multimedia, 2008, 10(6): 1073-1084.
- [25] Gao Y, Tang J H, Hong R C, et al. Camera constraint-free view-based 3-D object retrieval [J]. IEEE Transactions on Image Processing, 2012, 21(4): 2269-2281.
- [26] Wen Y, Gao Y, Hong R C, et al. View-based 3D object retrieval by bipartite graph matching [C] // Proceedings of the 20th ACM international conference on Multimedia, October 29-November 2, 2012, Nara, Japan. New York: ACM, 2012: 897-900.
- [27] Ansary T F, Daoudi M, Vandeborre J P. A Bayesian 3-D search engine using adaptive views clustering [J]. IEEE Transactions on Multimedia, Institute of Electrical and Electronics Engineers, 2007, 9(1): 78-88.