

中图法分类号: TP391 文献标志码: A 文章编号: 1006-8961(2011)03-0442-07

论文索引信息: 刘建军, 夏胜平, 郁文贤. 一种利用熵函数和 Affinity Propagation 聚类的超图模型优化方法 [J]. 中国图象图形学报, 2011, 16(3): 442-448

一种利用熵函数和 Affinity Propagation 聚类的超图模型优化方法

刘建军¹⁾, 夏胜平¹⁾, 郁文贤²⁾

¹⁾(国防科技大学电子科学与工程学院 ATR 重点实验室, 长沙 410073) ²⁾(上海交通大学电子信息与电气工程学院, 上海 200030)

摘要: 属性图相似性阈值对类属超图(CSHG)模型的训练结果具有重要影响。在满足聚类准确性的条件下, 利用定义的熵函数给出优化 CSHG 模型结构的相似性阈值, 并得到初始优化的 CSHG 模型, 进一步利用 FTOG 之间的相似性矩阵得到最简 CSHG 模型结构。另外, 利用亲缘传播聚类(affinity propagation clustering)方法去除 FTOG 聚类中的冗余属性图, 最终得到最优的 CSHG 模型。实验结果表明, 本方法是有效的。

关键词: 相似性图聚类; 类属超图; 熵函数; 亲缘传播

An optimization method for CSHG model using entropy function and Affinity Propagation clustering

Liu Jianjun¹⁾, Xia Shengping¹⁾, Yu Wenxian²⁾

¹⁾(State Laboratory of Automatic Target Recognition, National University of Defense Technology, Changsha 410073 China)

²⁾(School of Electronic, Information and Electrical Engineering, Shanghai JiaoTong University, Shanghai 200030 China)

Abstract: CSHG (class specific hyper graph) model is largely influenced by the threshold of the similarity measure between two graphs. By setting a constraint to fault tolerance of clustering, the similarity measure threshold for initial optimized CSHG model is obtained using the entropy function defined on CSHG model and the initial optimized CSHG model is thus constructed. The similarity matrix of FTOG is then created and the most simplified CSHG structure is obtained. In addition, the redundant graphs in FTOG are detected and deleted using affinity propagation method and the final optimized CSHG model is acquired. Experimental results demonstrate the reliability and effectiveness.

Keywords: graph-clustering; class specific hyper-graph; entropy; affinity propagation

0 引言

在对图像目标的检索、识别等应用中, 建立图像目标的描述模型是很重要的一个环节。借鉴文本检索中关键词向量空间模型的思想, 文献[1-2]中基于特征包(BoF)的思想建立图像目标的描述模型。

然而, 简单的基于特征包的方法存在一个明显的不足, 就是其关键特征被当做一个无序的特征集而没有利用特征的空间布局, 而特征之间的几何约束关系恰恰是视觉目标识别的重要线索之一。为了更好地对图像目标进行建模, 很多学者试图建立特定的概率模型, 对局部特征之间的相对位置关系、尺度关系以及特征的检测概率综合描述, 如文献[1-3]建

收稿日期: 2009-10-10; 修回日期: 2009-12-24

基金项目: 国家自然科学基金项目(60972114)。

第一作者简介: 刘建军(1980—), 男, 国防科技大学电子科学与工程学院博士研究生, 主要从事计算机视觉与目标识别研究工作。E-mail: lj_j_0606@sina.com。

立的模型,它们可以看做是基于特征包模型的扩展。但是,这类模型存在模型训练参数规模很大以及只适应于很小的成像条件变化范围的缺点。若将一幅图像的局部特征及其空间布局关系作为一个整体,可以基于属性图理论^[4]来表示和分析这种结构化的数据,如文献[5]基于k扇区图结构使用高斯分布来描述目标部分之间的几何关系,文献[6]使用遗传算法从训练集得到一张中心图等,但是这些建模方法同样只适应于成像条件在小范围内变化的情况。

为了使得模型对成像条件的大范围变化具有适应性,文献[7]以图像的尺度不变特征变换(SIFT)^[8]为基础,提取出了图像的稳健SIFT特征^[7,9],而后利用属性图理论^[4],将每个图像目标状态用属性图进行描述,进而构造出以属性图为顶点,以属性图之间相似性关系为加权边的类属超图模型(CSHG),进行目标建模,对大量图像目标的性能测试取得了有意义的结果^[7]。在CSHG模型训练过程中,属性图相似性阈值对模型训练结果具有重要影响,在保证CSHG模型聚类准确性的条件下,本文利用CSHG模型上定义的熵函数求出了优化超图模型的属性图相似性阈值,并得到了初始优化的CSHG模型结构。进一步,利用初始优化的CSHG模型中FTOG聚类之间的相似性矩阵,合并最相似的FTOG聚类,得到最简的CSHG模型结构。另外,在CSHG模型中的各个FTOG聚类中存在冗余的属性图,本文基于亲缘传播聚类(affinity propagation clustering)^[10]方法去除了冗余的属性图,最终得到了优化的CSHG模型。实验证明,本文的方法得到了优化的CSHG模型,并且优化的CSHG模型具有良好的图像目标识别性能。

1 类属超图模型

对一幅图像 I ,利用文献[9]的方法,根据相似图像之间SIFT特征匹配的频度从图像中提取稳健的SIFT特征,作为对图像进行匹配、识别等处理的特征。从图像中选取出的稳健SIFT特征是一种结构化的数据,可以用属性图模型来表征这种结构化的数据^[4]: $G = (V, E)$,其中 V 表示属性图的顶点集, $E \subseteq V \times V$ 表示顶点之间的边集。这样,对于图像集可以建立对应的图集: $G = \{G_l, l = 1, 2, \dots, N\}$ 。定义任意两个属性图 G_l, G_q 之间的相似性度量^[7]为

$$R(G_l, G_q) = \|MCS(G_l, G_q)\| (\exp(-e(X_l, X_q)))^\kappa \quad (1)$$

式中, $\|MCS(G_l, G_q)\|$ 表示图 G_l, G_q 的最大公共子图 $MCS(G_l, G_q)$ 中SIFT特征点的数量, $e(X_l, X_q)$ 为图 G_l, G_q 之间的迭代procrustes匹配误差, κ 为匹配过程中去除的错误匹配特征点的数量。

以属性图为顶点,属性图之间的相似性度量为加权边,CSHG模型^[7]: $CSHG = (HV, HE)$,其中顶点集 $HV = \{G_l, l = 1, 2, \dots, N\}$ 是有限个属性图组成的集合, HE 是CSHG模型中边的集合,只有当属性图之间的相似性度量 $R(G_l, G_q)$ 大于设定的阈值 R_τ 时,超图的顶点 G_l 和 G_q 之间建立一条边。

当图像集规模很大时,利用相似性度量 $R(G_l, G_q)$ 得到与任一属性图 G_l 近邻的属性图集 $K\{G_l\}$ 将是很耗时的。为了提高CSHG模型训练的效率,基于文献[11]介绍的RSOM聚类树思想,快速检索到与属性图 G_l 相似的属性图集 $K'(G_l)$,这个集合是整个CSHG模型训练集的子集,在 $K'(G_l)$ 中找到与 G_l 具有边关系的属性图集,训练效率将大大提高。

对训练集中的任一属性图 G_l ,与其建立相邻边关系的属性图集满足^[7]:

$$S\{G_l\} = \{G_q \in K\{G_l\} \mid R(G_l, G_q) \geq R_\tau\} \triangleq S_{R_\tau}\{G_l\} \quad (2)$$

对 $S\{G_l\}$ 中的属性图,同样可以建立与其具有相邻边关系的集合,这样通过迭代的方法可以得到图 G_l 的家族树(FTOG)^[7]:

$$F\{G_l, k\} = F\{G_l, k-1\} \cup_{G_q \in F\{G_l, k-1\}} S_{R_\tau}\{G_q\} \quad (3)$$

式中,如果 $k=1$,则 $F\{G_l, 1\} = F\{G_l, 0\} \cup S\{G_l\}$, $F\{G_l, 0\} = \{G_l\}$ 。当 $F\{G_l, k\} = F\{G_l, k+1\}$ 时,迭代过程结束。FTOG模型属性图集是CSHG模型中属性图的子集,可以认为是属性图的聚类,这是一种非中心聚类,一个CSHG模型中含有一个或多个FTOG聚类。

2 类属超图模型的优化

2.1 优化CSHG模型中非中心聚类(FTOG)的数量

设某类属性图集用 g^+ 表示,聚类得到的CSHG模型为 $C_{R_\tau}\{g^+\}$, $C_{R_\tau}\{g^+\}$ 中所有FTOG聚类所含的正类属性图的数量用 TP 表示,其中所含的负类属性图的数量用 FP 表示,设所有正类属性图的数量

为 P , 定义如下 3 个聚类指标: precision(p), recall(r) 以及 F-measure(f):

$$p\{R_\tau | g^+, g^-\} = TP / (TP + FP) \quad (4)$$

$$r\{R_\tau | g^+, g^-\} = TP / P \quad (5)$$

$$f\{R_\tau | g^+, g^-\} = \frac{2}{1/p + 1/r} \quad (6)$$

指标 f 表征了正类属性图集 g^+ 聚类的准确性。

定义属性图集 g^+ 聚类得到的 CSHG 模型 $C_{R_\tau}\{g^+\}$ 上的熵函数:

$$E\{C_{R_\tau}\} = - \sum_{l=1}^{L_N} \{p_l \log p_l\} \quad (7)$$

$$p_l = \frac{\|F_l\|}{\sum_{l=1}^{L_N} \|F_l\|} \quad l = 1, 2, \dots, L_N \quad (8)$$

式中, $\|F_l\|$ 表示 F_l 中属性图的数量。

由式(7)可知, CSHG 模型聚类的结果受属性图之间相似性阈值 R_τ 的影响。当 R_τ 设置为较大的数值时, CSHG 模型具有较高的聚类准确性, 模型中将会有较多的 FTOG 聚类; 当 R_τ 设置为较小的数值时, CSHG 模型的聚类准确性将降低, 模型中 FTOG 聚类的数量将会减少。我们希望找到合适的阈值 R_τ , 使得 CSHG 模型满足一定的聚类准确性, 即 $f > 1 - \varepsilon$, 同时 CSHG 模型具有精简的结构。

式(7)的熵函数值反映了 CSHG 模型中 FTOG 聚类的情况, 在满足 $f > 1 - \varepsilon$ 的条件下, 使式(7)的熵函数取最小值的阈值 R_{τ_1} 是满足我们要求的阈值, 此阈值下得到的 CSHG 模型具有精简的结构, 即有

$$\begin{cases} R_{\tau_1} = \max \{ \arg \min_{R_\tau} E\{C_{R_\tau}\} \} \\ \text{s. t. } f\{R_\tau | g^+, g^-\} > 1 - \varepsilon \end{cases} \quad (9)$$

综上, 在 CSHG 模型召回准确率满足一定准确性的条件下, 精简 CSHG 模型中非中心聚类 FTOG 数量的算法(Algorithm 1)步骤为

1) 设定 CSHG 模型召回准确率指标 f 的阈值 $1 - \varepsilon$ 。

2) 任选阈值 R_τ , 计算在此阈值下聚类得到的 CSHG 模型的 f 和 $E\{C_{R_\tau}\}$, 若 $f > 1 - \varepsilon$, 转 3); 若 $f < 1 - \varepsilon$, 舍弃该阈值 R_τ , 重新选择阈值 $R'_\tau > R_\tau$, 直到满足 $f > 1 - \varepsilon$, 并记录此时的熵函数值 $E\{C_{R_\tau}\}$ 。

3) 减小阈值 R_τ , 并记录该阈值下聚类的 f 和熵函数值 $E\{C_{R_\tau}\}$, 当 $E\{C_{R_\tau}\}$ 达到最小且满足 $f > 1 - \varepsilon$ 时的阈值 R_τ 即为所求的阈值, 此阈值 R_τ 条件下得

到的 CSHG 模型具有精简的结构。

Algorithm 1 中, CSHG 模型中所有的 FTOG 聚类具有相同的阈值 R_τ , 这时的 CSHG 模型结构并不是最精简的。若根据 FTOG 聚类的相似性进一步改变某些 FTOG 聚类的相似性阈值 R_τ , 并合并这些 FTOG 聚类后, 聚类准确性条件 $f > 1 - \varepsilon$ 仍然满足, 则可以利用这种思想逐步得到最精简的 CSHG 模型结构。

对于 Algorithm 1 中得到的 CSHG 模型, 我们定义该 CSHG 模型中所有 FTOG 之间的相似度组成的矩阵为

$$\mathbf{M} = [s_{ij}]_{m \times n} \quad (10)$$

式中, $s_{ij} = \max_{i,j} (R(G_i, G_j))$, $R(G_i, G_j)$ 为由式(1)定义的属性图 G_i, G_j 之间的相似性度量。 $G_i \in \text{FTOG}_m, G_j \in \text{FTOG}_n$, $\text{FTOG}_m, \text{FTOG}_n$ 是 CSHG 模型中的任意两个 FTOG 聚类。如果我们找到矩阵 \mathbf{M} 中元素的最大值 s_{\max} , 并找出 s_{\max} 对应的 FTOG_m 和 FTOG_n , 那么以 FTOG_m 和 FTOG_n 中的任一属性图为初始聚类属性图, 以 s_{\max} 为相似性阈值进行聚类, FTOG_m 和 FTOG_n 将会合并。如果 FTOG_m 和 FTOG_n 合并后得到的新的 CSHG 模型仍满足 $f > 1 - \varepsilon$, 且熵函数值 $E\{C_{R_\tau}\}$ 进一步减小, 那么此时的 CSHG 模型是更简化的 CSHG 模型结构。在新的 CSHG 模型中迭代进行这个过程, 直到不满足 FTOG 合并的条件, 将会得到最简的 CSHG 模型结构。基于此, 在 Algorithm 1 得到初始精简的 CSHG 模型的基础上, 我们设计了最简 CSHG 模型结构生成算法 (Algorithm 2):

1) 由 Algorithm 1 得到初始简化的 CSHG 模型, 记录此时属性图聚类的阈值 R_τ , 以及 CSHG 模型聚类准确率指标 f 和熵函数值 $E\{C_{R_\tau}\}$ 。

2) 计算得到的 CSHG 模型中 FTOG 聚类两两之间的相似性, 组成相似性矩阵 \mathbf{M} 。

3) 在相似性矩阵 \mathbf{M} 中, 找出最大值 s_{\max} 对应的 FTOG_m 和 FTOG_n , 以 s_{\max} 为属性图相似性阈值, 以 $\text{FTOG}_m, \text{FTOG}_n$ 中任一属性图为聚类初始属性图进行聚类, 得到新的 CSHG 模型。

4) 计算新的 CSHG 模型的 f 和熵函数值 $E\{C_{R_\tau}\}$, 若满足 $f > 1 - \varepsilon$, 且 $E\{C_{R_\tau}\}$ 变小, 则保存原 CSHG 模型, 对新的 CSHG 模型, 转 2); 若 $f < 1 - \varepsilon$, 则转下步。

5) 舍弃该次生成的 CSHG 模型, 上次生成的 CSHG 模型即为最简的 CSHG 模型。

6) 输出最简的 CSHG 模型。

2.2 精简 FTOG 中的冗余属性图

某类数据集的 CSHG 模型训练完成后,其中的非中心聚类 FTOG 中含有冗余的属性图,这些冗余的属性图使得 CSHG 模型占用更大的内存空间,而去除这些冗余的属性图并不会影响 CSHG 模型在识别、检索等应用中的性能,因此,有必要去除 FTOG 中的冗余属性图。这里采用亲缘传播 (AP) 聚类^[10]的方法找出 FTOG 中的非冗余属性图,并去除冗余的属性图。

亲缘传播 (AP)^[10]是一种聚类方法,初始时它将所有待聚类的数据点看做潜在的聚类中心点 (exemplar),通过在以数据点为节点的网络上传递信息逐步完成聚类。在聚类过程中,每个传递的信息的幅度表示了一个数据点作为另一个数据点的类中心点的支持程度。经过迭代,最终完成数据集的聚类。

AP 算法以数据点之间的相似度 $s(i, k)$ 组成的矩阵 S 作为输入,算法运行时不需要预先设定聚类数,改变偏向参数 (preference) $s(k, k)$ 的值将改变聚类的数目。AP 算法定义了两种在数据点间传递的信息量,分别为代表 (responsibility) 信息 $r(i, k)$ 和适用 (availability) 信息 $a(i, k)$,它们分别根据下式进行更新:

$$r(i, k) \leftarrow s(i, k) - \max_{k', s.t. k' \neq k} \{a(i, k') + s(i, k')\} \quad (11)$$

$$a(i, k) \leftarrow \min\{0, r(k, k) + \sum_{i', s.t. i' \in \{i, k\}} \max\{0, r(i', k)\}\} \quad (12)$$

自我适用性 (self-availability) 表示了数据点 k 作为类代表点的适合程度,根据下式进行更新:

$$a(k, k) \leftarrow \sum_{i', s.t. i' \neq k} \max\{0, r(i', k)\} \quad (13)$$

算法收敛以后,对任一数据点 i ,使得 $r(i, k) + a(i, k)$ 取最大值的数据点 k 就是数据点 i 的类代表点。若 $i = k$,则表示数据点 i 本身是一个类代表点。

在 CSHG 模型的非中心聚类 FTOG 中,以其中的属性图作为 AP 算法聚类的数据点,以属性图相似性度量值 $R(G_i, G_j)$ 作为数据点之间的相似度,组成相似性矩阵 S ,并设定初始的偏向参数 $s(k, k)$ 。采用 AP 算法聚类完成后得到的聚类中心点就是 FTOG 中非冗余属性图。去除 FTOG 中冗余属性图,保留非冗余属性图,这样就得到了精简的 FTOG 聚

类模型。

综上,基于 AP 算法得到精简的 FTOG 聚类模型的算法 (Algorithm 3) 步骤为

1) 初始化,根据式 (1) 得到 FTOG 中属性图之间的相似度 $s(i, k)$,所有属性图之间的相似度组成相似度矩阵 S ,设定 FTOG 中每个属性图的偏向参数 $s(k, k)$,设定初始的代表信息 $r^{(0)}(i, k) = 0$ 和适用信息 $a^{(0)}(i, k) = 0$ 。

2) 代表信息和适用信息根据式 (11) — (13) 进行迭代更新,当满足迭代终止条件时停止迭代,根据代表信息和适用信息的和式确定每个属性图的类中心属性图,并确定类中心的数量。

3) 判断得到的类中心是否满足要求,若不满足则改变偏向参数 p 的值,重复进行 AP 聚类过程,直到满足要求停止,输出聚类结果。

对 CSHG 模型中每个 FTOG 聚类都采用该方法得到其非冗余属性图,最终得到所有的精简 FTOG 聚类模型。

3 仿真实验

3.1 实验数据

训练图像集包括 53 536 幅图像,这些图像来自超过 500 类的目标,其中包括 Coil-100 数据集的 50 类目标,每类目标有 72 幅图像,共 3 600 幅图像,来自文献 [12] 中的 8 类目标,共 161 幅图像,以及我们搜集的另外 49 775 幅图像,部分训练图像示例如图 1 所示。对每幅训练图像,根据文献 [9] 中的方法,提取了该幅图像的稳健 SIFT 特征点,实验中训练图像的稳健 SIFT 特征点的数量最多选为 40 个,对每幅图像建立了对应的属性图。所有训练图像共提取了 2 140 000 个 SIFT 特征,建立了 53 536 个属性图。利用训练图像集的 SIFT 特征,我们训练了一棵具有 25 334 个叶子节点的 RSOM 聚类树^[11]。对图 1(a) 中的 10 类目标 (文中称为目标 A_1 — A_{10}) 以及图 1(b) 中的 8 类目标 (文中称为 B_1 — B_8),采用本文第 2 节的方法,分别得到了它们优化的 CSHG 模型,以及优化的 CSHG 模型对应的熵函数值 E 、聚类准确性指标 f 和非冗余属性图的数量。训练时,该类目标的图像作为正类图像,其他所有类的图像作为负类图像。文中实验是在 MATLAB 环境下,2 GB 内存,2.14 GHz 的计算机上进行的。



图 1 训练图像集和测试图像集的部分目标

Fig. 1 Part of objects for training and testing

另外,建立了本文的测试图像集。对图 1(a)中的 10 类目标的图像加入高斯噪声和椒盐噪声混合的噪声,噪声方差从 0.03、0.04、0.05 中随机选取,每幅图像合成了 6 幅加噪的图像,10 类目标共合成 4 320 幅图像,组成测试数据集 1。对图 1(b)8 个目标对应于文献 [12] 中的测试图像,采用手工的方法分出了每个待识别目标所在的区域,从 51 幅测试图像中共分出了 78 个目标区域,组成测试数据集 2。

对测试数据集 1 和测试数据集 2 中的图像都根据文献 [7] 的方法得到了它们对应的属性图,用于目标识别性能的测试。

3.2 优化 CSHG 模型中 FTOG 数量

采用 2.1 节中的 Algorithm 1 和 Algorithm 2 得到了图像目标 A_1 — A_{10} 和 B_1 — B_8 对应的优化 CSHG 模型的熵函数值 E 和召回准确率指标 f , 实验结果如表 1—4 所示。

表 1 A_1 — A_{10} 在两种算法中得到的优化 CSHG 模型对应的熵函数值Tab. 1 Entropy E of the optimized CSHG model of object A_1 — A_{10} in two algorithms

算法	A_1	A_2	A_3	A_4	A_5	A_6	A_7	A_8	A_9	A_{10}
Algorithm 1	0	0	0	0	0	0	0	0	0.38	0
Algorithm 2	0	0	0	0	0	0	0	0	0.15	0

表 2 B_1 — B_8 在两种算法中得到的优化 CSHG 模型对应的熵函数值Tab. 2 Entropy E of the optimized CSHG model of object B_1 — B_8 in two algorithms

算法	B_1	B_2	B_3	B_4	B_5	B_6	B_7	B_8
Algorithm 1	0.70	0.28	0.29	0	0.28	0	0.52	0.17
Algorithm 2	0.47	0.17	0.13	0	0.12	0	0.32	0.12

表 3 A_1 — A_{10} 在两种算法中得到的优化 CSHG 模型对应的 F-measureTab. 3 F-measure of the optimized CSHG model of object A_1 — A_{10} in two algorithms

算法	A_1	A_2	A_3	A_4	A_5	A_6	A_7	A_8	A_9	A_{10}
Algorithm 1	1.0	1.0	1.0	1.0	0.68	1.0	1.0	1.0	1.0	1.0
Algorithm 2	1.0	0.96	1.0	1.0	0.60	1.0	1.0	1.0	1.0	1.0

表 4 B_1 — B_8 在两种算法中得到的优化 CSHG 模型对应的 F-measureTab. 4 F-measure of the optimized CSHG model of object B_1 — B_8 in two algorithms

算法	B_1	B_2	B_3	B_4	B_5	B_6	B_7	B_8
Algorithm 1	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Algorithm 2	1.0	0.94	0.96	1.0	0.97	0.96	0.95	0.94

从表 1 可以看出,由 Algorithm 1 和 Algorithm 2 得到的 CSHG 模型中,除了目标 A_9 ,对应的熵函数值都为 0,这是因为它们每个目标的图像集有 72 幅图像,这些图像视角间隔 5° ,包含了 360° 视角的图像,这些目标的 CSHG 模型中只有一个 FTOG 聚类。从表 2 可以看出,由于 $B_1—B_8$ 对应的数据集相对于 $A_1—A_{10}$ 具有更复杂的背景,它们各自的 CSHG 模型中包含多个 FTOG。Algorithm 1 得到了初始优化的 CSHG 模型,Algorithm 2 相对于 Algorithm 1 熵函数进一步减小,得到了更加简化的 CSHG 模型。

从表 3 可以看出,训练图像集中存在与 A_5 很相似的负类图像,其聚类准确性受到影响,其他的目标都具有较好的聚类准确性。从表 4 可以看出,对

$B_1—B_8$,由 Algorithm 1 得到初始简化的 CSHG 模型,由 Algorithm 2 对初始简化的 CSHG 模型进一步简化时有少量其他类的图像进入部分目标 CSHG 模型中,这些目标的 CSHG 模型的聚类准确性有所下降,但是这时的聚类准确性仍然较高,能够满足在识别、检索等应用中的需要。

3.3 去除 FTOG 中的冗余属性图

利用本文 2.2 节的方法精简 FTOG 聚类中的冗余属性图,实验中 AP 算法的偏向参数初始设为矩阵 S 的中值。表 5、表 6 所示分别为 $A_1—A_{10}$ 和 $B_1—B_8$ 未去除冗余属性图时 CSHG 模型中各 FTOG 聚类所含的属性图总数以及去除冗余属性图后所含的非冗余属性图总数的对比。

表 5 精简前后 $A_1—A_{10}$ 对应的 CSHG 模型中所含属性图数量的对比

Tab. 5 The number of graphs in CSHG of $A_1—A_{10}$ before and after optimization

图像类型	A_1	A_2	A_3	A_4	A_5	A_6	A_7	A_8	A_9	A_{10}
精简前	72	72	72	72	72	72	72	72	72	72
精简后	34	32	27	34	23	19	23	30	15	32

表 6 精简前后 $B_1—B_8$ 对应的 CSHG 模型中所含属性图数量的对比

Tab. 6 The number of graphs in CSHG of $B_1—B_8$ before and after optimization

图像类型	B_1	B_2	B_3	B_4	B_5	B_6	B_7	B_8
精简前	29	20	16	16	16	16	28	20
精简后	27	19	16	16	16	15	27	18

从表 5 和表 6 可以看出,由于 $A_1—A_{10}$ 各个目标图片的视角有规则的变化, $A_1—A_{10}$ 各个目标 CSHG 模型中的非冗余属性图约占属性图总数的 $1/3$ 。 $B_1—B_8$ 中每个目标各个视角的图像最多只有 29 个,这些图像的属性图几乎都是非冗余的。

3.4 精简后的 CSHG 模型用于目标识别

对测试数据中的每类目标,设其待识别图像数量为 N ,根据 K-近邻方法作出识别判决的待识别图像数量为 N_R ,作出判决的图像中正确识别的图像数量为 N_T ,定义识别的准确率指标

$$f = \frac{2}{1/p + 1/r} \quad (20)$$

式中, $r = \frac{N_R}{N}$, $p = \frac{N_T}{N_R}$

我们测试了优化后的 CSHG 模型对测试数据集 1 和测试数据集 2 的识别准确率 f ,并将测试数据集 2 的识别结果与文献[12]中的方法进行了比较,识别结果分别如表 7、表 8 所示。从表 7 可以看出,对测试数据集 1 识别准确率在 0.95 以上。在表 8 中,本文的方法与文献[12]的方法具有相近的识别准

表 7 优化后的 CSHG 模型对测试数据集 1 的识别准确率

Tab. 7 Recognition ratio for test set 1 using optimized CSHG

测试类型	A_1	A_2	A_3	A_4	A_5	A_6	A_7	A_8	A_9	A_{10}
F-measure	0.97	0.95	1.0	0.97	1.0	1.0	1.0	0.98	0.95	0.97

表 8 优化后的 CSHG 模型对测试数据集 2 的识别准确率

Tab. 8 Recognition ratio for test set 2 using optimized CSHG

测试类型	B_1	B_2	B_3	B_4	B_5	B_6	B_7	B_8
本文方法	0.625	1.0	1.0	1.0	0.714	1.0	0.953	1.0
文献[13]方法	0.625	1.0	1.0	1.0	0.714	1.0	1.0	1.0

确率,但是本文的识别方法是在存在大量负类图像的条件下进行的。由于目标 B_1 和 B_5 训练数据集不够充分,对这两类目标的识别准确率较低。

4 结 论

由于受到视点、光照以及背景杂波等条件的影响,图像目标识别成为了一个具有挑战性的难题。CSHG 模型结合了不同视角下图像局部不变特征的全局和局部信息,对影响图像目标识别的多种因素具有适应性。属性图相似性对 CSHG 模型的建立具有重要影响,本文给出了优化 CSHG 模型结构的属性图相似性阈值求解方法,以及去除 CSHG 模型 FTOG 聚类中冗余属性图的方法。采用本文的方法得到了优化的 CSHG 模型,减小了模型所占的内存空间,有利于模型在识别、检索能方面的应用。

参考文献 (References)

- [1] Li Feifei, Perona P. A Bayesian hierarchical model for learning natural scene categories [C]// Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition. San Diego, CA, USA: IEEE Computer Society, 2005, 2(2):524-531.
- [2] Sivic J, Russell B C, Efros A A, et al. Discovering objects and their location in images [C]// Proceedings of the 10th IEEE International Conference on Computer Vision. Beijing: IEEE Computer Society, 2005, 1(1):872-877.
- [3] Kadir T, Brady M, Zisserman A. An invariant method for selecting salient regions in images [C]// Proceedings of the 8th European Conference on Computer Vision. Prague: Springer, 2004, 1(1):345-457.
- [4] Chung F, Spectral graph theory [C]// CBMS Regional Conference Series in Mathematics, Conference Board of the American Mathematical Science. Washington, DC: American Mathematics Society, 1997, 92:57-58.
- [5] Crandall D J, Huttenlocher D P. Weakly supervised learning of part-based spatial models for visual object recognition [C]// Proceedings of the 9th European Conference on Computer Vision, Graz: Springer, 2006, 3951(1):16-29.
- [6] Jiang X, Munger A, Bunke H. On median graphs: Properties, algorithms, and applications [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(10): 1144-1151.
- [7] Xia Shengping, Hancock E R. Pairwise similarity propagation based graph clustering for scalable object indexing and retrieval [C]// Proceedings of the 7th IAPP-TC-15 Workshop on Graph-based Representations in Pattern Recognition. Venice, Italy: Springer, 2009, 5534:184-194.
- [8] Lowe D. Distinctive image features from scale-invariant key points [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [9] Xia Shengping, Ren Peng, Hancock E R. Ranking the local invariant features for the robust visual saliencies [C]// Proceedings of the 19th International Conference on Pattern Recognition. Tampa, Florida, USA: IEEE, 2008: 1-4.
- [10] Frey B J, Duech D. Clustering by passing messages between data points [J]. Science, 2007, 315(5814):972-976.
- [11] Xia Shengping, Liu Jianjun, Yuan Zhentao, et al. Cluster-computer based incremental and distributed RSOM data-clustering [J]. ACTA Electronica Sinica, 2007, 35(3):385-391. [夏胜平, 刘建军, 袁振涛, 等. 基于集群的并行分布式 RSOM 聚类 [J]. 电子学报, 2007, 35(3):385-391.]
- [12] Rothganger F, Lazebnik S, Schmid C, et al. 3D object modeling and recognition using local affine-invariant image descriptors and multi-view spatial constraints [J]. International Journal of Computer Vision, 2006, 66(3): 231-259.