

中图法分类号: TP391.4 文献标志码: A 文章编号: 1006-8961(2012)01-0099-07

论文引用格式: 姜永兵, 彭启民. 目标识别中的稳定图像特征组合发掘 [J]. 中国图象图形学报, 2012, 17(1): 99-105

目标识别中的稳定图像特征组合发掘

姜永兵^{1,2} 彭启民¹

1. 中国科学院软件研究所综合信息系统国家级重点实验室, 北京 100190; 2. 中国科学院研究生院, 北京 100049

摘要: 针对图像局部特征组合稳定性差和区分力不足的问题, 通过对由图像半局部邻域特征挖掘得到的频繁项集进行统计学过滤、模式分解、模式总结及模式组成项间几何关系的建模, 提出两种具有较强表征力和区分力的图像中层表示模型: 类间共用稳定模式(inter-class common stable pattern) 和类内特殊稳定模式(intra-class special stable pattern)。在将这两种模式引入目标识别框架后, 得到了相比同类方法较好的结果。

关键词: 频繁项集; 模式分解; 模式总结; 稳定模式

The mining of stable image feature-compositions in object recognition

Jiang Yongbing^{1,2}, Peng Qimin¹

1. National Key Laboratory of Integrated Information System Technology, Institute of Software, Chinese Academy of Sciences, Beijing 100190, China; 2. Graduate University of Chinese Academy of Science, Beijing 100049, China

Abstract: In order to improve the stability and discrimination of local feature combination for image representation, two image mediate-level representations, Inter-CSP (inter-class common stable pattern) and Intra-SSP (intra-class special stable pattern) are proposed. The details of processing are given, which can be divided into statistic-filtering, pattern decomposition, pattern summarization and item-based geometric relation modeling on frequent item_sets mined from image semi-local features. A recognition framework is introduced based on Inter-CSP and Intra-SSP. The experiment results demonstrate that these two kinds of patterns are superior to classical methods.

Key words: frequent item set; pattern decomposition; pattern summarization; stable pattern

0 引言

数据挖掘在结构化和半结构化数据的检索、分类及识别领域取得了较大成功。从图像中提取的基本特征(视觉基元), 通过聚类产生视觉词汇, 从而用一组视觉词汇来表示(即 BoW) 图像, 用文本相关的知识解决部分视觉问题^[1-2]。但与文本词汇的离散性不同, 视觉基元具有连续性, 将其映射到视觉词汇会破坏这种性质, 导致对应视觉词汇的多变性和不确定性^[3]; 同样的视觉模式, 由于视角、光照、尺

度、噪声等因素的影响, 不可能用确定视觉基元对这种视觉模式进行表示。虽然通过聚类产生的视觉词汇量化会消除部分影响, 但高维连续空间数据到低维空间的映射具有不确定性, 同类目标的同种视觉模式可能映射到不同的视觉词汇(即同义性), 而不同目标的不同视觉模式也可能映射到相同的视觉词汇(即多义性)。

解决上述问题的一种方法是将视觉词汇放在具有空间约束的上下文中, 即同时出现的多个词汇比单个词汇更具确定性^[2-4]。半局部邻域即是组织方式之一, 其将局部特征与其附近的特征联合编码产

收稿日期: 2011-01-21; 修回日期: 2011-04-08

第一作者简介: 姜永兵(1984—), 男, 现为中国科学院软件研究所计算机应用专业硕士研究生, 主要研究方向为计算机视觉、图像处理、模式识别、机器学习等。E-mail: yongbing08@yahoo.com.cn

生视觉词汇组合,大多采用 K 邻域或自适应窗口编码, K 邻域对距视觉词汇最近的 K 个词汇进行无序编码来产生半局部邻域特征组合^[3-4]。自适应窗口则是对落在与编码视觉词汇对应的视觉基元尺度成比例的邻域窗口内的词汇进行编码,其邻域的定义更有弹性,产生的事务数据更能体现目标局部组件之间的依赖性^[2-5]。为了利用局部组件的空间信息,Quack 等人^[5]将自适应的窗口划分成 3×3 的网格对视觉词汇进行编码,在背景简单的图像中取得了较好的效果。但视觉词汇的空间约束关系具有连续性,对图像局部区域进行空间划分会造成模式的丢失;Zheng 等人^[4]提出的增量视觉模式在一定程度上保证了编码的连续性,但复杂度偏高。Nowozin 等人^[6]将整幅图像表示成图结构,用图挖掘的方法产生公用模式,组织方式更适用于背景、结构简单的目标识别分类。考虑到空间量化的影响,本文用自适应窗口的编码方法组织产生数据。

数据组织完毕后,用数据挖掘的方法产生稳定的视觉模式。但由于光照、偏转、遮挡、噪声等因素的影响,会得到数量庞大的特征组合,如果仅仅得到频繁项集,而不进一步处理,会严重限制模式的应用范围^[7];尤其是噪声和背景模式,会大幅降低挖掘产生的特征组合的区分力及稳定性。

本文用模式分解的方法对长模式进行分解,以提高分离出噪声模式和背景模式的概率,防止图像背景或噪声模式与目标真正模式的交叉;在经过统计学过滤^[3]之后,通过模式总结^[8]的方法重新产生目标完整的模式;由于 BoW 模型的泛化性过强,最后通过对稳定模式组成项之间的几何关系进行 GMM 建模,选取特征间稳定的分布信息,克服 BoW 的不足,产生有语义信息的特征组合。从上述步骤中提取类内特殊稳定模式和类间共用稳定模式,用其来提升视觉应用系统的性能。

1 基本概念

1.1 频繁项集定义

对图像库 X 中任一图像 I ,提取视觉基元 f_i ,用 K -均值聚类产生词汇表 $\Omega = \{W_1, W_2, \dots, W_M\}$, $|\Omega| = M$ 称 W_k 为视觉词汇。 $\forall f_i$ 通过 $\phi(f_i, \Omega)$ 映射到一个视觉词汇。 I 表示为 $I = \{w_i\}$ ($w_i \in \Omega$, 可相同)。对 $\forall w_i \in I$,用自适应半邻域编码产生以 w_i

为中心的视觉词汇集合: $g_i = \{R_0, R_1, \dots, R_K\}$ 其中 $R_i = \{w_{i0}, w_{i1}, \dots, w_{in}\}$, 满足 $d_{\text{eud}}(f_i, f_{ij}) \leq 5f_{i_scale}$, $\phi(f_i, \Omega) = w_i, \phi(f_{ij}, \Omega) = w_{ij}, j = 0, 1, \dots, n, d_{\text{eud}}(x, y)$ 表示 x, y 之间的欧氏距离。每幅图像产生集合 $G = \{g_1, g_2, \dots, g_M\}$, 且 $|G| = |I|$ 。图像库 $D_1 = \{I_i\}_{i=1}^{|\mathcal{I}|}$ 产生事务数据库 $D = \{G_1, G_2, \dots, G_{|\mathcal{I}|}\}$, T 为图像库中图像个数, G_i 为第 i 幅图像产生的数据集, 产生 $W = \sum_{i=1}^{|\mathcal{I}|} |G_i|$ 组事务数据。

设项集 $A \subseteq \Omega$, 若事务数据 T_i 满足 $A \subseteq T_i$, 则 T_i 支持 A ; 设 $D(A) = \{T \mid A \subseteq T, T \in D\}$, $D(A)$ 为 A 的支持集, 模式 A 的频率 $\text{frq}(A) = |D(A)|$, A 的支持度为

$$\text{sup}(A) = \frac{\text{frq}(A)}{|D|} = \frac{|D(A)|}{|D|} \quad (1)$$

如果 $\text{sup}(A) \geq \theta$, θ 是最小支持度, 则 A 是频繁的。由 Apriori 先验原理知,若一个频繁项频繁, 则其所有子集均频繁^[9]。本文采用闭频繁项集,其定义为不存在具有相同支持度超集的频繁项集。采用 FP-Closed 算法^[9]得到。

1.2 图像稳定模式定义

定义 1 模式 挖掘算法产生的频繁项集或对频繁项集总结后产生的视觉词汇集合。

定义 2 模式分解 将势过大的模式进行分解,降低模式集合的颗粒度大小。

定义 3 图像模式的稳定性 在受到不同背景或噪声干扰的情况下,目标图像共同点(模式)重复再现性。图像模式的稳定性在衡量模式的有效性上有极其重要的作用。

定义 4 稳定模式 不易受背景或噪声干扰的模式。

定义 5 类间共用稳定模式 整个图像库的稳定模式。类间稳定模式组合可以从更高层次上将待识别的图像库进行粗略划分。

定义 6 类内稳定模式 目标图像的稳定模式。

定义 7 类内特殊稳定模式 组成项间具有语义约束关系的类内稳定模式。从本质上将目标特征组合区别于其他相同的目标特征组合。

2 稳定模式的产生及匹配算法

稳定模式提取流程如图 1 所示,其中黑色方框内为稳定模式提取的主要算法及步骤。

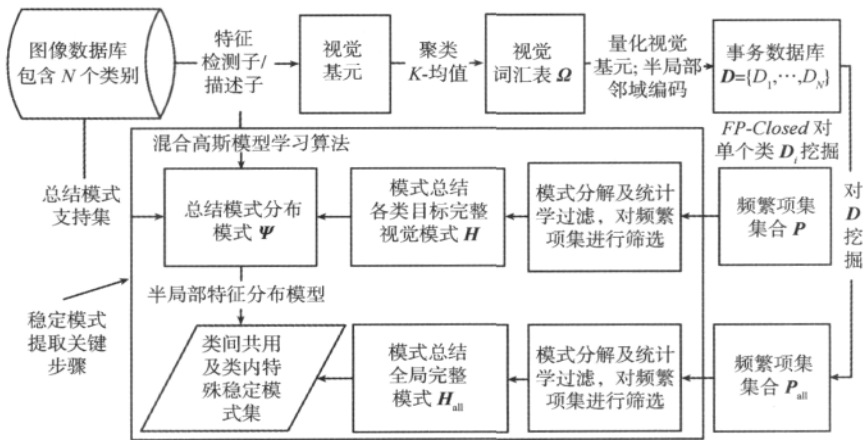


图 1 稳定模式提取流程

Fig. 1 Flow of extract stable patterns

2.1 无序频繁项集 P 的产生

FP-Closed^[9]挖掘算法只是单纯地产生闭频繁项集,不保证其实际意义。在视觉领域,由于目标易受噪声和目标所处背景的干扰,挖掘得到的频繁项集不仅包含目标本身的特征组合,也包含背景和噪声的特征组合,从而降低目标本身特征组合的区分力和稳定性。本文采用模式分解和统计学过滤来消除上述因素的影响。

2.1.1 模式分解

提取长度在 $[L_{min}, L_{max}]$ 内的闭频繁项集。对于长度超过 L_{max} 的模式进行模式分解,一方面提高噪声或背景模式单独分离出的概率;另一方面降低后期统计学测试的复杂度。模式分解是一个 NP-完全问题^[10],为了提高分解的速度和最终结果的有效性,采用程序 1) 的分解步骤:

- 1) 由 FP-Closed 算法得到闭频繁项集集合 B。
- 2) 建立集合 $H = \{a \in B, L_{min} \leq |a| \leq L_{max}\}$ 。
- 3) 建立空集合 E。
- 4) 对每一个长度超过 L_{max} 的频繁项集 $b \in B$,
 - (1) 找到集合 $C = \{a \in H, a \subseteq b\}$;
 - (2) 计算出 C 中各个频繁项集的并集 b_1 ;
 - (3) 如果 $b \subseteq b_1$, 则说明 H 覆盖 b 将 b 删除;
 - (4) 如果 $b_1 \subseteq b, b \neq b_1$, 说明 b 是 b_1 的超集, 计算 $d = b - b_1$; 如果 $|d| < L_{min}$, 删除 b; 如果 $|d| \geq L_{min}$, 则将 d 有排除的加入集合 E 中(判断 E 中是否存在 d, 如果存在且 d 支持度大于原来支持度, 更新 d 在 E 中支持度, 如果不存在则直接将 d 加入 E 中)。

5) 若 $\exists e, e_1 \in E, e \subseteq e_1, \text{sup}(e) = \text{sup}(e_1)$, 则删除 e。

6) $F = H \cup E$ 。

7) 返回 F。

命题 1 程序 1 得到的 F 为闭频繁项集集合。

证明 只有步骤 (4) 会产生项集 d。频繁项集的所有子集均频繁, 而 $d \subseteq b$ 故 d 是频繁项集。

假设 d 非 H 中闭频繁项集, 则 $\exists c \in H, b \subseteq c$, 且 $\text{sup}(b) = \text{sup}(c)$, 但在步骤 (2) (3) 保证不存在 $c \in H, b \subseteq c$, 矛盾。故 d 为 H 中闭频繁项集。

步骤 (4) 保证, 若 $\exists e \in E, e = d, \text{sup}(e) \neq \text{sup}(d)$, 则 $\text{sup}(d) = \max(\text{sup}(e), \text{sup}(d))$ 。

故对 $\forall e \in E, \text{sup}(e) = \max\{\text{sup}(a) \mid a \in E, a = e\}$; 经过步骤 5), 保证 E 为闭频繁项集集合; 从而对 $\forall e \in E, e$ 为 $H \cup E$ 的闭频繁项集; 故最终的集合 F 为闭频繁项集集合。证毕。

2.1.2 重复编码及图像支持度过滤

特征重复编码由以下两种方式产生:

1) 图像事务数据库中的事务数据在空间编码区域上存在重复编码的情况, 如图 2(a) 所示, 组合“CDH”被重复编码。

2) 纹理性较强的背景或目标。如图 2(b) 所示, 组合“AB”被重复编码。

特征组合的图像支持度^[3, 11]定义为

$$\rho_{\text{sup}}(A) = \frac{|\{I_i \mid \exists T_j \in G_i, A \subseteq T_j\}|}{|X|} \quad (2)$$

其衡量了频繁模式和目标本身的相关性, 可以剔除大量无意义模式。

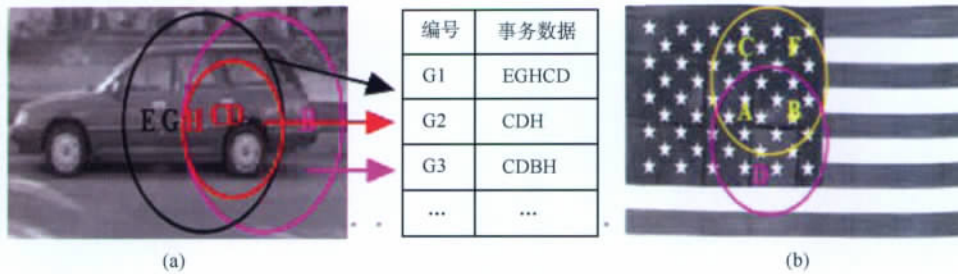


图 2 空间重复编码示意图

Fig. 2 Spatial-overlap coding

2.1.3 冗余表达及 t -检验

高阶频繁模式易受噪声模式的干扰。用 t -检验对每个模式长度为 2 的所有子集进行测试^[3], 以此来消除噪声模式的干扰。

$$t(\{A, B\}) \approx \frac{\text{freq}(\{A, B\}) - \frac{\text{freq}(A)\text{freq}(B)}{N'}}{\sqrt{\text{freq}(\{A, B\})}} \quad (3)$$

$\text{freq}(\{A, B\})$ 表示模式 $\{A, B\}$ 在训练集中出现的频率, $N' = N/K$, N 表示 $\{A, B\}$ 支持集中出现词汇集合的大小, K 为提取的事务数据的长度, 为 $\{A\}$ 和 $\{B\}$ 所有支持集的平均长度。

与文献[3]不同, 对不满足 t -检验的频繁项集, 这里不将整个频繁项集删除, 而是将不满足检验的 2-长度子集中的一个或者两个项从原频繁项集中删除, 使保留下来的频繁项集的全部 2-长度子集满足检验; 如果经过 t -检验后的频繁项集在集合中存在, 则更新此频繁项集支持度, 否则将此频繁项集放入频繁项集集合。上述步骤不会引入错误的闭频繁

项集, 且可将没有贡献的噪声或背景模式剔除。

2.1.4 目标频繁项集的提取

非目标本身的特征组合主要由图像中噪声及背景干扰产生。假设噪声和背景特征的分布为随机分布, 且与目标上的特征分布相互独立。

采用如下的统计性度量以进一步删除噪声及背景模式

$$L(p) = \frac{P(p | H_1)}{P(p | H_0)} = \frac{\text{freq}(p) / N}{\prod_{a \in p} \text{freq}(a) / N} \quad (4)$$

$P(p | H_0)$ 表示假设频繁项集为随机分布时的概率, $P(p | H_1)$ 表示频繁项集在训练集中的实际概率。

根据 $L(p)$ 筛选出前 K (200) 个频繁项集; 从训练图像集中随机选择 Λ (15) 幅图像作为验证图像, 选取在验证图像集中出现次数最多的频繁项集作为此轮验证得到的频繁项集, 重复验证 J 次, 得到 J 个频繁项集。最终产生的模式如图 3(a) 所示。

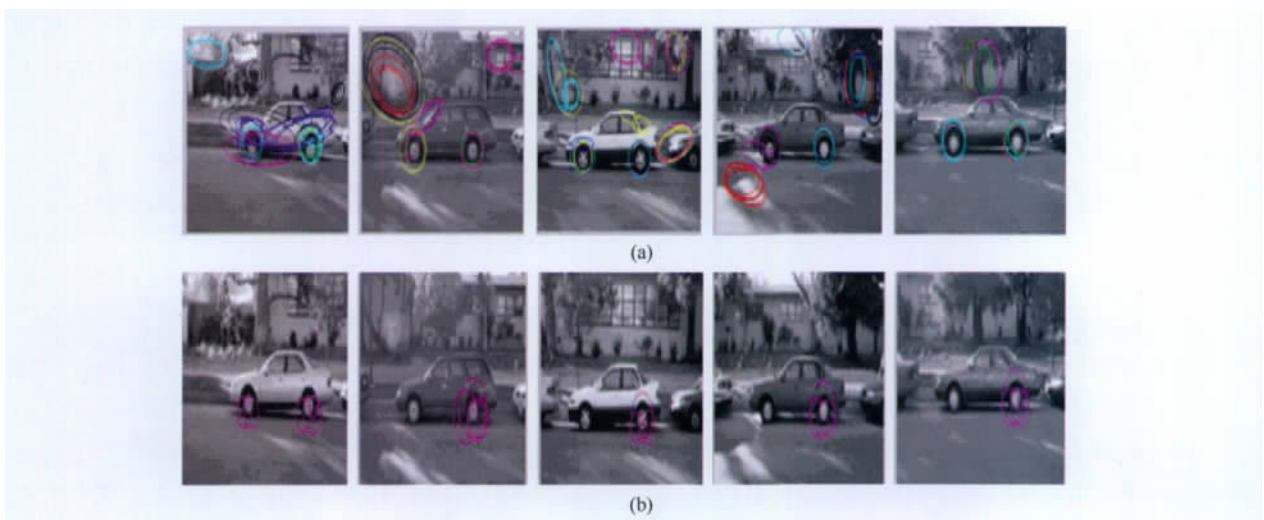


图 3 总结模式建模前后

Fig. 3 Summarized patterns before and after modeling

图 3(a) 是经过模式分解及统计学过滤后各个频繁项集在目标图像上的显示; 图 3(b) 是经过模式总结以及空间信息建模之后汽车某一总结模式(后车轮) 在目标上的表示。

2.2 完整模式-模式总结

模式总结的方法从频繁项集集合 P 产生完整模式。其将表现及统计学意义上相似的频繁项集进行归并, Yan^[8] 用 Kullback-Liebler 测度(也称为交叉熵, KL 距离, 相对熵) 在频繁项集、支持集相关性方面有较好的表征能力, 但对组成项间的表现相似性表征不足。我们将频繁项集之间的表现相似性用频繁项集间的编辑距离或其他相似性度量表示, 将两个相似性度量相乘, 得到最终的总体相似性, 然后用 NCA^[12] 进行聚类。参照前面的模式长度限制, 本文将总结后的模式长度限制在 $1.5L_{max}$ 之下, 防止 NCA 过聚类。

对频繁项集 p_i, p_j , 定义其表现相似性为

$$r(p_i, p_j) = \exp\left(\frac{|p_i \cap p_j|}{|p_i \cup p_j|}\right) \quad (5)$$

两者之间的相似度为

$$s(p_i, p_j) = r(p_i, p_j) \cdot s_{sKL}(p_i, p_j) \quad (6)$$

式中 $s_{sKL}(p, q) = (s_{sKL}(p|q) + s_{sKL}(q|p))/2$; $s_{sKL}(p|q)$ 表示 p 与 q 的相对熵, 即

$$s_{sKL}(p|q) = \int p(x) \ln(p(x)/q(x)) dx$$

支持集为此模式的所有频繁项集的支持集, 即

$$D(p) = \{D(p_1), D(p_2), \dots, D(p_k)\} \quad (7)$$

式中 $p = p_1 \cup p_2 \cup \dots \cup p_k$, $D(p)$ 为 p 的支持集。

到此步骤为止, 分别得到整个数据库上的类间共用稳定模式和各个目标库上的类内稳定模式。

2.3 产生类内特殊稳定模式

对各个局部特征之间的几何约束关系进行建模。本文利用如下 3 类几何关系:

1) 归一化距离。视觉基元 A, B 在图像上对应位置的欧氏距离与两者较大尺度值的比值, 即

$$n(A, B) = d_{eud}(A, B) / \max(A_{scale}, B_{scale}) \quad (8)$$

2) 尺度比例。最小尺度与最大尺度的比值, 即

$$s(A, B) = \frac{\min(A_{scale}, B_{scale})}{\max(A_{scale}, B_{scale})} \quad (9)$$

3) 局部特征主方向夹角, 即

$$\vartheta = |A_{ori} - B_{ori}| \quad (10)$$

归一化距离表征局部特征之间的距离分布, 尺度比例表征局部特征检测粒度(关键点检测时周边区域大小) 的关系, 局部特征主方向夹角表征局部

特征之间的相对空间方位信息。

本文对无序稳定模式中所有项两两进行高斯混合分布建模, 选取概率最高的高斯函数作为分布函数。高斯混合分布在特征间分布关系建模方面具有较好的性能^[13]。理论上, 混合高斯分布可以表达任意的分布, 该方法不仅能处理均匀和高斯分布这些理想数据分布, 还能很好地处理任意真实数据分布。高斯混合模型的训练采用 EM 算法。分别对各类目标采用此种方法, 即得到类内特殊稳定模式。

2.4 模型匹配算法

共用稳定模式, 通过事务数据与特征模式的交集来判定两者是否匹配; 对类内特殊稳定模式, 则采用程序 2) 的全局匹配策略进行匹配。

输入: 图像 I 不变特征集合 F , F 量化视觉词汇集合 V ; 总结模式 p_i 对应的分布模型 Ψ_i 。

输出: 匹配的视觉基元空间几何信息 M 。

1) 对 $\forall v_j \in \Psi_i, node$, 求取 V 中与其视觉词汇相同的局部特征信息 V_j , 即 $V_j = \{flf(F, v_j) = v_j\}$ 。

2) 对 $\forall v_i, v_j \in \Psi_i, node, i \neq j$, 从 Ψ_i 的分布信息中提取 v_i, v_j 对应的混合高斯模型参数。

(1) 对 V_i, V_j 中的任意一对元素计算其归一化距离、尺度比及主方向夹角的分布概率; 如果 3 个概率有至少两个不小于 Ψ_i 对应几何信息的阈值, 就说找到了一个满足模型的边; 将满足模型的节点及视觉基元信息放入 M_{ij} ;

(2) 如果 M_{ij} 非空, 则将匹配边个数加 1。

3) 如果匹配边个数 ≥ 3 或者等于 Ψ_i 中非空边的个数, 并且具有公共项的点对个数大于 2, 则说明此模型在图像 I 中存在匹配。

4) 返回匹配信息 M 。

建模后示例如图 3(b) 图像, 由图可见, GMM 建模可以将某些不稳定的模式和背景模式剔除。

3 实验结果及分析

本文实验基于 Caltech101 图像库, 不包括 faces_easy 类(与 faces 类重复)。视觉词汇大小为 1 000。每类中用 30 幅图像作为正类训练样本, 测试样本从各类没有参与训练的集合中随机选取。局部特征检测子采用 DoG^[14] 描述子用 SIFT^[14]。频繁项支持度为 $0.25 \times$ 训练图像样本数/特征总数, 图像支持度为 0.25。共用频繁模式, 从整个图像库中用第 2、3 节的

步骤提取;特殊频繁模式用第 2—4 节的步骤提取;然后将图像组织成向量表示形式,进行 SVM 分类识别。为了全面验证算法的性能,设计如下的对比实验和分组实验。

1) 分组实验

- (1) 模式分解及统计学过滤的有效性;
- (2) 共用稳定模式的 K 邻域 BoW;
- (3) 共用稳定模式自适应 BoW 识别方法;
- (4) 运用本文提出的特殊稳定模式及共用稳定模式的自适应识别方法。

2) 对比实验

- (1) 整幅图像 BoW 的识别算法;
- (2) Lazebnik^[15]的空间金字塔识别算法;
- (3) Nowozin^[6]的图挖掘方法;
- (4) 本文提出的识别方法。

3.1 实验结果

1) 分组实验结果 如表 1 所示。

表 1 分组实验结果

Table 1 Grouping experiment results

分组实验	平均识别率/%	误差/%	对应图表
(1)	—	—	图 3
(2)	64.1	1.9	图 4 (b)
(3)	78.3	1.6	图 4 (c)
(4)	90.3	2.3	图 4 (d)

2) 对比实验结果 如表 2 所示。

表 2 对比实验结果

Table 2 Compare experiments results

对比实验	平均识别率/%	误差/%	对应图表/文献
(1)	56.6	2.1	图 4 (a)
(2)	67.6	1.4	Lazebnik ^[15]
(3)	85.3	2.3	Nowozin ^[6]
(4)	90.3	2.3	图 4 (d)

图 4 的 x 轴表示 Caltech101 库类别名称按字母序排列后的编号,如 accordion 对应 1; y 轴表示各个类别对应的各个算法运行 3 次的平均识别率。

3.2 实验结果分析

从图 3 (a) 图像模式看出,进行分解和统计学过滤可将大部分树叶、地面上光斑、小棵灌木等噪声或背景模式剔除。分解降低了模式的颗粒度,从而将这些噪声或背景模式独立出来;进行统计学独立性检验,剔除随机性强的噪声模式;而图像支持度过滤,则剔除大部分背景模式。图中并没有剔除全部的背景模式(图像中的树干、窗),原因是训练图像背景单一。另外,图 3 (a) 中第 4 幅图像中会产生车体阴影模式,此种模式不是背景或噪声模式,将其剔除需要更高层的语义约束关系,不属于本文中语义模式的范畴。图 3 (b) 图像已将汽车的轮子作为完整模式提取出来,并且不再像图 3 (a) 那样产生模式间的混淆。

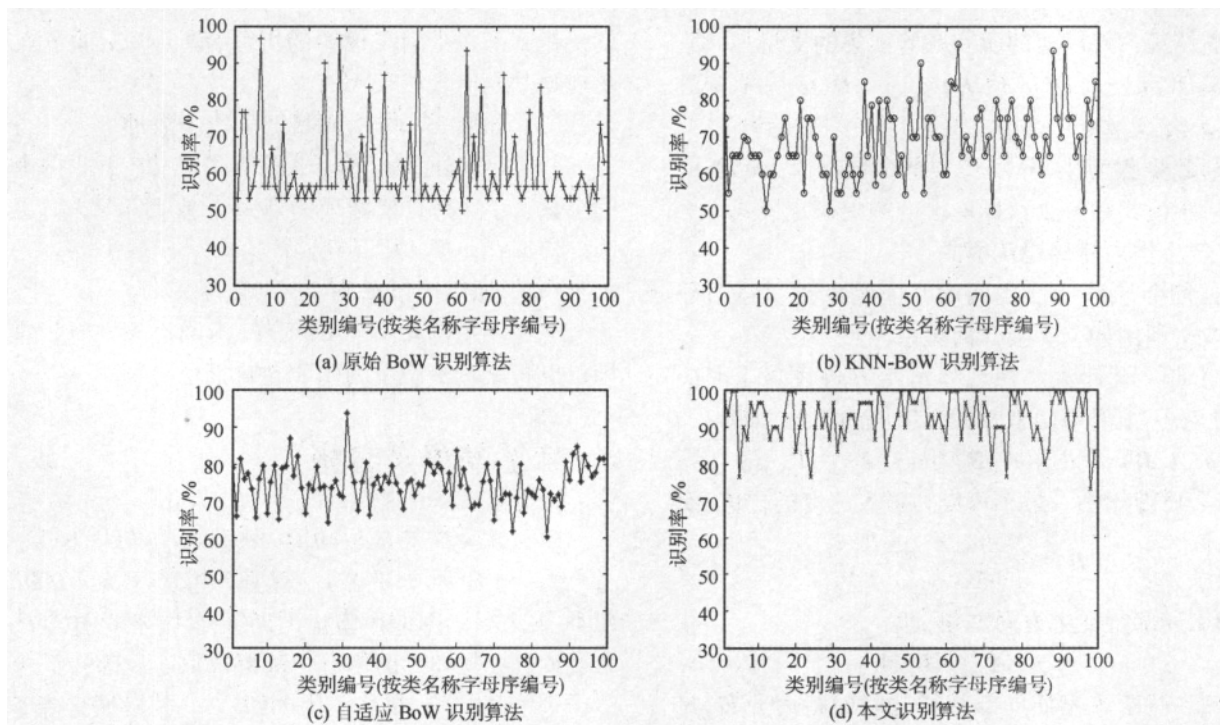


图 4 实验结果

Fig. 4 Experiment Results

图 4(b) 中识别率较高的目标大多为表现特征较明显的人造目标, 验证了共用频繁模式具有从高层次分类目标的能力。图 4(c) 则说明自适应的 Bow 邻域编码比 K 邻域编码更能把握目标的局部特征组合, 与理论上的分析相符。图 4(d) 说明在自适应模型引入几何约束的特殊稳定模式后, 增强了模式的区分力和稳定性, 从而进一步提高了识别效率。

从图 4 还可以看出, 对于某些类, 引入几何约束信息反而使识别率下降, 这主要是由训练集不足造成。对于较小的训练集, 提取得到的模式在某些类别内并不具有代表性, 而几何信息的引入又增加了这些模式的特殊性, 使在测试数据中特殊模式的检测率下降, 进而导致识别率下降。

4 结 论

针对图像局部特征区分力不足及特征组合稳定性差的问题, 提出稳定模式的图像中层表达形式, 包括类间共用稳定模式和类内特殊稳定模式。所提模式在半局部邻域特征编码的基础上通过模式挖掘、模式分解、统计学过滤、模式总结和模式项间关系建模等 5 个步骤得到。实验表明, 本文所提模式具有较强的区分力和稳定性, 提高了系统的识别率。此种稳定模式由于含有较强的语义信息, 通过对各个稳定模式之间关系的进一步建模, 将来可以应用于目标检测等相关计算机视觉领域。

参考文献(References)

- [1] Jamieson M, Dickinson S, Stevenson S, et al. Using language to drive the perceptual grouping of local image features [C] // Proceeding IEEE Conference on Computer Vision and Recognition. New York, USA: IEEE Press 2006: 2102-2019.
- [2] Wang Y S, Gao W. Kernel-based image classification using the context of visual words[J]. Journal of Image and Graphics 2010, 15(4): 607-616. [王宇石, 高文. 用基于视觉单词上下文的核函数对图像分类[J]. 中国图象图形学报, 2010, 15(4): 607-616.]
- [3] Yuan J S, Wu Y, Yang M. Discovery of collocation patterns: from visual words to visual phrases[C]//Proceeding IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis, USA: IEEE Press 2007: 1-8.
- [4] Zheng Y T, Zhao M, Neo S Y, et al. Visual synset: towards a higher-level visual representation [C] //Proceeding IEEE Conference on Computer Vision and Pattern Recognition. Alaska, USA: IEEE Press 2008: 1-8.
- [5] Quack T, Ferrari V, Leibe B. Efficient mining of frequent and distinctive feature configurations [C] //Proceeding IEEE International Conference on Computer Vision, Rio de Janeiro, Brazil: IEEE Press 2007: 1-8.
- [6] Nowozin S, Tsuda K. Weighted substructure mining for image analysis [C] //Proceeding IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos, CA, USA: IEEE Press, 2007: 1-8.
- [7] Fang L L, Wang X H. Research of image mining [J]. Computer Science, 2009, 36(8): 30-34. [方玲玲, 王相海. 图像挖掘研究[J]. 计算机科学 2009, 36(8): 30-34.]
- [8] Yan X F, Cheng H, Han J W, et al. Summarizing itemset patterns: a profile-based approach [C] //Proceedings ACM SIGKDD International Conference on Knowledge Discovery in Data Mining. NY, USA: ACM Press 2005: 314-323.
- [9] Han J W, Cheng H, Xin D, et al. Frequent pattern mining: current status and future directions [J]. In Data Mining and Knowledge Discovery 2007, 15(1): 55-86.
- [10] Jin R M, Xiang Y, Liu L. Cartesian contour: a concise representation for a collection of frequent sets [C] //Proceedings ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. NY, USA: ACM Press 2009: 417-426.
- [11] Li J. Research and Application of Local Invariant Image Feature [D]. Beijing: Iscas 2008. [黎俊. 图像不变局部特征研究与应用[D]. 北京: 中国科学院软件研究所 2008.]
- [12] Shi J, Malik J. Normalized cuts and image segmentations [J]. Pattern Analysis and Machine Intelligence, 2000, 22(8): 888-905.
- [13] Karlinsky L, Dinerstein M, Harari D, et al. The chains model for detecting parts by their context [C] //Proceeding IEEE Conference on Computer Vision and Pattern Recognition. San Francisco, CA: IEEE Press 2010: 25-32.
- [14] Lowe D G. Distinctive image features from scale-invariant key points [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [15] Lazebnik S, Schmid C, Ponce J. Beyond bags of features: spatial pyramid matching for recognizing natural scene categories [C] // Proceeding IEEE Conference on Computer Vision and Recognition. New York, USA: IEEE Press 2006: 2169-2178.