

面向非合作目标识别的大规模类属超图建模

夏胜平¹, 宋 锐¹, 刘建军¹, 张乐峰¹, 虞 华¹, Edwin Hancock²

(1. 国防科学技术大学电子科学与工程学院 ATR 实验室, 湖南长沙 410073;

2. 英国约克大学计算机系)

摘 要: 针对大量不同成像条件下获得的多视图像, 研究利用局部不变特征及其空间布局约束构建用于非合作目标识别的类属超图模型的方法. 该方法首先将每一幅图像表示为使用选定的稳健 SIFT 特征构成的属性图, 然后提出了一种属性图相似性传播聚类原理. 在给定的 F 度量的约束下, 利用该原理进行聚类, 并根据熵函数最小化优化条件, 可迭代得到特定目标属性图样本集合的最优聚类, 进一步将所获得的聚类简化成以非冗余属性图作为节点的类属超图模型. 本文用大量图像样本进行了试验测试. 实验结果验证了模型的可扩展性和识别性能.

关键词: 目标识别; 类属超图; 局部不变特征; 属性图; 尺度不变特征

中图分类号: TP18 **文献标识码:** A **文章编号:** 0372-2112 (2011) 06-1399-06

Learning Large Scale Class Specific Hyper Graphs for Non-Cooperative Object Recognition

XIA Sheng-ping¹, SONG Rui¹, LIU Jian-jun¹, ZHANG Le-feng¹, YU Hua¹, Edwin Hancock²

(1. State Lab of ATR, National University of Defense Technology, Changsha, Hunan 410073, China;

2. Department of Computer Science, University of York, York YO10 5DD, UK)

Abstract: This paper describes how to construct a class specific hyper-graph (CSHG) model from a large corpus of multi-view images using local invariant features and their spatial configuration. As the first step of this method, each image is represented with a graph, which is constructed from a group of selected robust SIFT features. Secondly, a similarity propagation based graph clustering (SPGC) method is then proposed. Using this clustering method, the positive example graphs of a specific class accompanied with a set of negative example graphs are clustered into one or more clusters, which minimize an entropy function with a restriction defined on the F-measure. Based on SPGC and the rules of minimizing an entropy function, each cluster is simplified into a tree structure composed of a series of irreducible graphs. Finally, a recognition oriented class specific hyper-graph is generated from the given graph set. Using a trained CSHG model, object recognition can be implemented. Experimental results demonstrate the scalability and recognition performance of the method.

Key words: object recognition; class specific hyper graph; attributed graph; local invariant feature; SIFT (Scale Invariant Feature Transform)

1 引言

基于图像局部不变特征^[1~4]的光学图像非合作目标识别方法逐渐取代基于全局特征的方法成为了主流. 在图像局部不变特征提取的基础上, 基于特征包 (BoF: Bag-of-Feature) 的图像表征和目标建模方法是一类典型方法^[5~9]. 然而, 简单 BoF 方法的显著不足在于将关键特征当作无序特征集而未利用特征的空间几何约束关系, 这正是视觉目标识别的重要线索, 大量测试表明这类方法的性能受到制约. 近年来, 针对图像局部特征及其几何约束关系构建综合模型的研究占据了主导地位.

以文[2, 5, 6, 9]为典型代表的方法试图建立特定的

概率模型, 综合描述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. 这类模型的主要弱点是其假设模型复杂, 模型训练参数规模很大; 且模型只适应于较小的成像条件变化范围.

事实上, 若某成像条件连续变化, 则所观测图像序列应具有一定的“特征轨迹”. 不妨把一个目标想象成一理想成像模型, 所有成像条件作为成像系统参数, 目标的每一幅图像则可看作给定条件下系统的一个输出状态, 所有状态构成目标的具有一定随机性的“特征轨迹”. 在众多成像条件和随机因素的综合作用下, 目标特征轨迹非常复杂, 形成了由多个简单特征轨迹混合成的特征轨迹簇, 这难以用一般的高维空间曲线、曲面或者

几何体进行描述. 本文的出发点就是要建立一种模型使之对这种潜在的、具有随机性的“复杂特征轨迹簇”具有适应性.

本文利用局部不变特征和图像相似性传播原理来构建目标模型. 首先, 以图像局部特征为基础, 将目标的每一幅图像表征为一组特征向量, 这些隐含了特定空间布局的特征数据被看作一个属性图, 对应于目标成像的一个状态或轨迹点. 而后将每个属性图看成一个更抽象的图的顶点, 再根据属性图之间的相似性关系定义属性图之间的边, 从而构造出具有类专属特性的超图模型用于描述这种潜在的“复杂特征轨迹簇”.




图1 目标特征表象的轨迹特性示意图

2 属性图及属性图相似性度量

SIFT算法详见文献[3]. 对于一幅图像, 一个 SIFT 特征点向量 $\mathbf{V}^t = (\mathbf{X}^t, \mathbf{R}^t, \mathbf{U}^t)$ 包括了特征点的坐标, 梯度幅值和方向, 以及 128 维 SIFT 特征向量, 所有特征点组成集合 $\mathbf{V} = \{\mathbf{V}^t, t = 1, 2, \dots, m\}$.

给定 $V_l = \{\mathbf{V}_l^t, t = 1, 2, \dots, m_l\}$ 和 $V_q = \{\mathbf{V}_q^t, t = 1, 2, \dots, m_q\}$. 对 V_l 中的一个 SIFT 特征值向量 $\mathbf{U}_l^{t_1}$, 其在 V_q 中的最近邻向量记为 $\mathbf{U}_q^{t_{q1}}$, 次最近邻向量记为 $\mathbf{U}_q^{t_{q2}}$, 当且仅当

$$\gamma = d(\mathbf{U}_q^{t_{q1}}, \mathbf{U}_l^{t_1}) / d(\mathbf{U}_q^{t_{q2}}, \mathbf{U}_l^{t_1}) \leq \gamma_\tau \quad (1)$$

$$\text{s.t. } d(\mathbf{U}_q^{t_{q1}}, \mathbf{U}_l^{t_1}) \leq \epsilon_\tau$$

时, 将 $\mathbf{U}_q^{t_{q1}}$ 和 $\mathbf{U}_q^{t_{q2}}$ 称为正匹配对. 其中 $d(\cdot) = \|\cdot\|_2$, ϵ_τ 和 γ_τ 是预定义的门限.

一幅图像中的 SIFT 特征点若能稳健地和与之相似图像的 SIFT 特征点匹配, 则可将这些特征看作显著特征. 文献[10]据此提出了根据正匹配频度对 SIFT 特征点进行排序的方法. 试验表明, 对单幅目标图像, 稳健特征点数量 T 取 40 时可在匹配效率和匹配性能间取得较好的平衡. 由此, 一幅图像转换成了一组具有一定空间约束关系的稳健特征点来描述, 而属性图为这种数据的表征提供了理论工具.

属性图是一个 2 元组 $G = (V, E)$, 其中 V 是向量集合, 而 $E \subseteq V \times V$ 是边的集合. 对每幅图像, 用选定的稳健 SIFT 特征的坐标建立 Delaunay 图, 用每个 SIFT 特征点作为每个节点的属性. 这样, 可将一组图像表征为一

个属性图集合 $G = \{G_l, l = 1, 2, \dots, N\}$.

属性图匹配是求解 G_l, G_q 的最大公共子图 $\text{MCS}(G_l, G_q)$ (Maximum Common Subgraph: MCS), 的过程. 仅利用特征点之间的空间布局约束关系进行求解已被证明是一个 NP 问题. 若综合利用 SIFT 特征描述向量信息及其空间布局约束信息, $\text{MCS}(G_l, G_q)$ 的求解就变成了一个有约束条件的匹配问题, 最优解的搜索空间将急剧减小. 据此, 文献[11]采用两阶段 procrustes 迭代匹配方法实现了对 $\text{MCS}(G_l, G_q)$ 的高效求解. 进一步, 可定义两个图之间的相似性度量指标:

$$R(G_l, G_q) = \|\text{MCS}(G_l, G_q)\| \times (\exp(-e(\mathbf{X}_l, \mathbf{X}_q)))^K \quad (2)$$

其中 $\|\text{MCS}(G_l, G_q)\|$ 是 G_l 和 G_q 的最大公共子图的势; $e(\mathbf{X}_l, \mathbf{X}_q)$ 表示初始匹配中对应特征点坐标矩阵 \mathbf{X}_l 和 \mathbf{X}_q 之间 procrustes 匹配的最小二乘误差; K 是利用两阶段迭代 Procrustes 匹配从 SIFT 特征正匹配中最终去掉的错误匹配特征点对的数目.

两个图 G_l 和 G_q 相似性度量 R 大于给定门限, 则称二者是正匹配的, 记为 $P(G_l, G_q) = 1$, 否则为 0.

3 类属超图建模

3.1 构建初始类属超图

定义 1 类属超图

CSHG 是一个二元组 $\text{CSHG} = (HV, HE)$. 其中超顶点 $HV = \{G_l, l = 1, 2, \dots, N\}$ 是构成 CSHG 的节点的属性图集合. 当且仅当 $P(G_l, G_q) = 1$ 时节点 G_l 和 G_q 间存在一条边. 这样可以对 CSHG 的超顶点集 HV 的图集 $G = \{G_l, l = 1, 2, \dots, N\}$ 构造其超边集 HE .

对集合 $G, \forall G_l \in G, G_l = (V_l, E_l)$, 对所有图 $G_q \in G$, 根据式(2)求得其相似性度量 $R(G_l, G_q)$. 按相似度降序排列后, 选出 K 个取值较高的图, 记为

$$K_\tau \{G_l\} = \{G_q \mid R(G_l, G_q) \geq R_\tau\} \quad (3)$$

由此获得的属性图称之为图 G_l 的 K 近邻. 由此定义图 G_l 与其 K 近邻之间存在的边构成了类属超图模型中的超边集 HE . 这里要补充说明的是, 本文采用文[15]中的 RSOM 聚类树用于增量学习大量的 SIFT 特征向量, 可实现 $K_\tau \{G_l\}$ 的均衡快速求解.

3.2 训练类属超图模型

3.2.1 相似性传播聚类

假设通过训练得到了初始 CSHG 模型, 并在将来用其它的图进行更新. $K_\tau \{G_l\}$ 中元素的数目主要受门限 R_τ 的影响. 为了能够从初始 CSHG 获得更为紧凑的表示, 首先给出两个基本的定义.

定义 2 图的兄弟(S)

图 G_l 的兄弟定义为:

$S\{G_l\} = \{G_q \in K_c \mid P(G_l, G_q) = 1\} \triangleq S_{R_c}\{G_l\}$ (4)
 $S_{R_c}\{G_l\}$ 是与图 G_l 满足正匹配关系的属性图集合。

在此基础上,提出一种基于相似性传播聚类的基本原理.其核心思想是对给定的 $G, \forall G_l \in G$,可从该图集中找到一组与 G_l 满足一定相似性关系的属性图,由这些属性图可以类似地找到满足一致的相似性约束的属性图,如此类推,直到没有新的属性图被找回,所有这些属性图形成一个聚类。

换言之, $\forall G_l \in G$,可以得到其兄弟 $S\{G_l\}$.对每个 $G_q \in S\{G_l\}$,又可获得其兄弟.这样,如此迭代可获得满足一致相似性约束关系的属性图集合,称之为图 G_l 的家族树。

定义 3 图的家族树 (FTOG)

对一个 CSHG 模型, G_l 的 k 代家族树为:

$$F\{G_l, k\} = F\{G_l, k-1\} \cup_{G_q \in F\{G_l, k-1\}} S_{R_c}\{G_q\} \quad (5)$$

其中 $F\{G_l, 1\} = F\{G_l, 0\} \cup S\{G_l\}$, $F\{G_l, 0\} = \{G_l\}$;该迭代过程在 $F\{G_l, k\} = F\{G_l, k-1\}$ 时停止。

对任意的 R_c ,总存在 $G_i, i = 1, 2, \dots, c$ 满足 $F\{G_i, g\} \cap F\{G_j, k-1\} = \Phi, i \neq j, i, j \in \{1, 2, \dots, c\}$,将这些图的家族树标记为 L_1, L_2, \dots, L_c , 记作:

$$C_{R_c} = \{F_{R_c}\{G_l, \infty\}\} = \{F_l \mid l \in \{L_1, L_2, \dots, L_c\}\} \quad (6)$$

若将某特定类的图看作正例,而所有其它类的样本都当作反例,则可将上述问题看作一个 2 类划分问题.形式上,对该分类器,每个实例或被映射为正例,或被映射为反例.可出现四种结果:正确的正例、错误的反例、正确的反例和错误的反例.将上述四种情况下样本的数目分别记为 TP 、 FN 、 TN 和 FP .可得到 2×2 的混淆矩阵.该矩阵是多种常用度量值,例如精度 p 、召回率 r 和 F 度量值 f 的基础。

将正例图集记为 g^+ ,反例图集记为 g^- .只考虑那些由 g^+ 中的图产生的 FTOG.可以重写式(9)为

$$C_{R_c}\{g^+\} = \{F_{R_c}\{G_l, \infty\}, G_l \in g^+\}$$

假设 $C_{R_c}\{g^+\}$ 中图的数目为 TP , $g^- \cap C_{R_c}\{g^+\}$ 中图的数目为 FP ,而 P 是 g^+ 中图的数目.对给定的 g^+ 和 g^- ,对每个 R_c ,可以将上述三个度量定义为:

$$\begin{aligned} p(R_c \mid g^+, g^-) &= TP / (TP + FP) \\ r(R_c \mid g^+, g^-) &= TP / P \\ f(R_c \mid g^+, g^-) &= \frac{2}{(1/p + 1/r)} \end{aligned} \quad (7)$$

对 $C_{R_c}\{g^+\}$ 可以定义熵为:

$$E(C_{R_c}) = - \sum_{l=1}^{L_c} (p_l \cdot \log p_l) \quad (8)$$

$$\text{其中, } p_l = \|F_l\| / \sum_{l=1}^{L_c} \|F_l\| \quad (9)$$

现在希望找到 R_{c1} 满足下列条件:

$$\begin{aligned} R_{c1} &= \max \{ \arg \min_{R_c} E\{C_{R_c}\} \}, \\ \text{s.t. } & F\{R_c \mid g^+, g^-\} > 1 - \epsilon \end{aligned} \quad (10)$$

其中的 ϵ 是识别错误容许门限 0.02.

显然,希望 $E\{C_{R_{c1}}\}$ 越小越好.如果 $E\{C_{R_{c1}}\} = 0$,则 g^+ 中的所有图都聚类到了一个 FTOG 中,此种情况下,若 F 度量也是 1,就表明没有任何其它的反例样本被聚类到该 FTOG 中.可以通过改变 R_c 进行迭代搜索得到式(10)条件下的最优聚类 $\{F_l \mid l \in \{L1, L2, \dots, L_c\}\}$,记作 $C_{R_{c1}}\{g^+\}$.

在求解式(10)时,通过减小阈值 $R_c, F\{R_c \mid g^+, g^-\}$ 可能显著减小.理论上,如果 g^+ 中存在 G_q 和 R_c 满足:

$$\lim_{\forall R_c \rightarrow \infty} \frac{\nabla F\{R_c \mid g^+, g^-\}}{\nabla R_c} \rightarrow \infty \quad (11)$$

G_q 就称为 g^+ 的混淆图(AG),记为 A_q .若混淆图 G_q 的兄弟未被用于根据式(5)建立 FTOG,且仍可获得式(10)的适当的解,则该 A_q 图被记为停止图.这类停止图意味着正例和反例之间存在非常相似的图像.这些图像对应的属性图是无显著差异的.若混淆图不多,可对其进行标记,组成混淆图集合 \bar{A} .若有很多相似度较低的混淆图,可以将得到的 FTOG 中的否定图合并到正例中,将其看作合并后的新的目标类别.这种混淆图集信息可以用于识别判决,因而集合 \bar{A} 是 CSHG 模型参数的一部分。

3.2.2 FTOG 的简化

假设给定相似性门限 $R_c > R_{c1}, G_q \in F_l$ 为冗余图的充分条件是:

(1)由式(5)仍然可以得到一个 FTOG: $F_l - G_q$ ($F_l - G_q$ 表示从 F_l 去掉属性图 G_q);

(2) G_q 至少有两个兄弟属于同一个 FTOG.

这时,可将 G_q 看作冗余图,并将其合并到与它相似性度量最大的兄弟图 G_j ,由此可迭代得到新的家族树 $F'_l \subseteq F_l$.记 G_j 满足前述条件的兄弟图数目为 N_{G_j} ,可以定义 F'_l 的熵函数为:

$$E\{F'_l \mid R_c, F_l\} = - \sum_{j=1}^{\|F'_l\|} (p_{G_j} \cdot \log p_{G_j}) \quad (12)$$

$$\text{其中 } p_{G_j} = \frac{N_{G_j}}{\sum_{k=1}^{\|F'_l\|} N_{G_k}}, j = 1, 2, \dots, \|F'_l\| \quad (13)$$

可求得极小化上述熵函数的相似性阈值:

$$R_{c0} = \arg \min_{R_c} E\{F'_l \mid R_c, F_l\} \quad (14)$$

这样可将 F_l 简化到由一组非冗余图 $G'_j, j = 1, 2, \dots, \|F'_l\|$ 及其相似性关系构成的 F'_l .

对 F'_l 中每个非冗余图 G'_j 构成的节点 k ,计算其特征匹配频度用于识别. F'_l 的大小取决于 F_l 和 R_{c0} ,是最

初获得的 FTOG 的更为紧凑的表示. 由于 R_{τ_0} 与 F'_l 相联系, 可以将其重写为 R_{l, τ_0} . 综上, F'_l 的定义为:

$$\begin{aligned} F'_l &\triangleq F'_l \{ R_{l, \tau_0}, R_{\tau_1}, \tilde{G}_l \mid g^+, g^- \} \\ &\triangleq F'_l \{ \theta_l \mid g^+, g^- \} = \{ \theta_l \mid g^+, g^- \}, \\ l &= 1, 2, \dots, L \end{aligned} \quad (15)$$

其中

$$\tilde{G}_l \triangleq \left\{ \left\{ \begin{aligned} &G_j^l, N_{G_j^l}, S_{R_{\tau_1}} \{ G_j^l \}, \\ &\{ n_k^l, k = 1, 2, \dots, G_j^l \} \end{aligned} \right\}, j = 1, 2, \dots, F'_l \right\} \quad (16)$$

$$\tilde{A}_l \triangleq \{ A_q \in F'_l, q = 1, 2, \dots, \|\tilde{A}_l\| \} \quad (17)$$

$$\theta_l \triangleq \{ R_{l, \tau_0}, R_{\tau_1}, \tilde{G}_l, \tilde{A}_l \}$$

由此, 从给定样本集 g^+ 和 g^- 训练得到了关注目标的类属超图模型, 记作 CSHG $\{ \theta \mid g^+, g^- \}$, 其中 $\theta = \{ \theta_l, l = 1, 2, \dots, L_c \}$.

3.2.3 FTOG 的生长

假设属性图数据集中存在 K 类关注目标类别, 可以对每一类目标分别进行模型训练, 得到其类属超图模型, 记作 CSHG $_k$, $k = 1, 2, \dots, K$. 在增量环境中, 根据和训练阶段相同的原理将新图 G_l 增加到类模型 CSHG $_k$ 中. 这些原则可以归纳为:

(1) 如果存在两个或以上的图 G_q 满足 $R(G_l, G_q) \geq R_{\tau_0}(F'_l \{ G_q \})$, 则 G_l 为冗余图.

(2) 如果存在 G_{q_0} 满足 $R(G_l, G_{q_0}) \geq R_{\tau_1}(F'_l \{ G_{q_0} \})$, 则增加 G_l 作为 $F'_l \{ G_{q_0} \}$ 的非冗余图. 如果有另一个图 $G_{q_1} \in F'_l \{ G_{q_1} \}$, 而 $F'_l \{ G_{q_0} \}$ 和 $F'_l \{ G_{q_1} \}$ 来自不同的类, 则记 G_l 为混淆图. 如果 $F'_l \{ G_{q_0} \}$ 和 $F'_l \{ G_{q_1} \}$ 属于相同的类, 则合并这两个 FTOG.

(3) 如果 $\max(R(G_l, G_q)) < R_{\tau_1}(F'_l \{ G_q \})$, 则建立新 FTOG 为 $F'_l \{ G_{q_0} \}$.

3.2.4 基于 CSHG 的识别测试

在训练得到 CSHG 模型后, 对测试图 G_l , 可获得 $K_r \{ G_l \}$, 然后根据其 K 近邻图的相似性度量 $R(G_l, G_q)$ 作为权重进行加权识别, 并用 F 度量对识别性能进行评估. 这里的 F 度量根据如下方式进行定义:

设测试数据中某类目标的待识别图像数量为 N , 识别时做出识别判决的待识别图像数量为 N_R , 做出判决的图像中正确识别的图像数量为 N_T , 则 F 度量定义为:

$$F = \frac{2}{1/p + 1/r}, \text{ 其中 } r = \frac{N_T}{N}, p = \frac{N_T}{N_R} \quad (18)$$

从上式可知, F 度量值越高意味着同时获得了高的召回率和精度, 理想的结果是 F 度量取值为 1.

4 实验结果和讨论

4.1 训练数据

本文使用来自超过 500 个目标, 包含人脸和场景的

53536 幅图像作为训练集, 图 2 为部分示例. 其中, 68 类物体作为感兴趣目标, 记作目标 1 至目标 68, 如图 2a、2b 和 2c. 对每幅图像, 用文献[10]中的方法提取稳健 SIFT 特征, 选择 40 个特征用于构建属性图. 从而可得到总计 53536 幅图和超过 2 百万个 SIFT 特征向量. 对这 68 个目标, 另外还收集了 26678 幅图像, 获得了相应的属性图及其特征向量作为测试集.



(a) 来自 Coil 100 的 50 个目标



(b) 来自文献[14]的 8 个目标



(c) 作者收集的 10 个目标



(d) 无标记的部分样本图像

图 2 训练和测试样本图像示例

图 2(a) 为 Coil 100 数据库中的 50 个目标, 记作 A_1 至 A_{50} , 共 3600 幅图像; 图 2(b) 是文献[14]使用的 8 个目标, 记作 B_1 至 B_8 , 共 161 幅图像; 图 2(c) 是作者收集的 10 个目标, 记作 C_1 至 C_{10} , 共 20000 幅图像; 图 2(d) 为 29875 幅来自其他标准数据库如 Caltech101^[5]、PASCAL VOC'07^[13] 和 Google 的无标记图像, 覆盖超过 450 个目标, 用作负例样本对 A_1 至 A_{50} , 通过对每幅图像添加椒盐、斑点或高斯噪声各生成 6 幅图像. 这些噪声的方差随机设置为 0.03、0.04、0.05. 总计获得 50 个目标的 21600 幅图像用于测试. 对 B_1 至 B_8 , 从文献[1]的 51 幅测试图像中获得了 78 个 ROI, 每个 ROI 包含一个关注的目标. 对 C_1 至 C_{10} 中的每个目标, 分别收集了与训练图像相似成像条件下的 500 幅图像用于测试.

4.2 训练结果

从这些训练数据, 可用文献[11]中的方法得到一棵有 25334 个叶节点的 RSOM 聚类树. 在增量训练阶段, 得到了每个图的 $K_r \{ G_l \}$. 接下来, 使用 3.2 节中的方法分别训练上述 68 个关注目标的 CSHG 模型.

5 结论

本文研究了从大量多视角图像获得面向识别的类属超图模型的方法. 该模型全面综合了来自不同视角的图像局部特征中所包含的全局和局部信息. 该模型无需严格的假设, 完全由数据驱动. 使用这一模型, 对感兴趣目标可始终获得较高的识别精度. 运用该模型可对所关注目标进行增量训练. 本文实验中, 最初仅训练了一类目标, 而最终模型中包含了 68 类感兴趣目标. 通过增量训练还可逐渐提高对感兴趣目标的召回率.

参考文献

- [1] H Bay, T Tuytelaars, L V Gool. Surf: Speeded up robust features [A]. European Conference on Computer Vision[C]. Graz, Austria: Springer-Verlag, 2006. vol. 3951, Part I: 404 – 417.
- [2] T Kadir, M Brady, A Zisserman. An invariant method for selecting salient regions in images[A]. Proc Eighth European Conference on Computer Vision[C]. Prague: Springer-Verlag, 2004. 345 – 457.
- [3] D. Lowe. Distinctive image features from scale-invariant key points[J]. International Journal of Computer Vision, 2004, 60(2): 91 – 110.
- [4] K Mikolajczyk C Schmid. A performance evaluation of local descriptors[J]. IEEE Trans on PAMI, 2005, 27(10): 1615 – 1630.
- [5] F F Li, P Perona. A bayesian hierarchical model for learning natural scene categories[A]. Intl Conf on CVPR[C]. San Diego, CA, USA; IEEE Press, 2005. 2(2): 524 – 531.
- [6] J Sivic, B C Russell, A A Efros, A Zisserman, W T Freeman. Discovering objects and their location in images[A]. International Conference on Computer Vision [C]. Beijing, China; IEEE Computer Society, 2005. 1: 370 – 377.
- [7] A Torralba, R Fergus, Y Weiss. Small codes and large image databases for recognition[A]. Intl Conf on CVPR[C]. Anchorage, Alaska; IEEE Press, 2008. 1 – 8.
- [8] Eric Nowak, et al. Sampling strategies for bag-of-features image classification[A]. European Conference on Computer Vision [C]. Graz, Austria; Springer-Verlag, 2006. LNCS vol. 3954, Part IV. 490 – 503.
- [9] J Philbin, J Sivic, A Zisserman. Geometric Latent Dirichlet Allocation(gLDA) model for unsupervised particular object discovery in unordered image collections [A]. BMVC [C]. Leeds, UK: British Machine Vision Association, 2008.
- [10] S P Xia, P Ren, E R Hancock. Ranking the local invariant features for the robust visual saliencies[A]. Proceedings of the 19th International Conference on Pattern Recognition [C]. Tampa, Florida, USA: IEEE, 2008. 1 – 4.
- [11] 刘建军, 夏胜平, 郁文贤. 基于 SIFT 特征的两阶段 procrustes 迭代匹配算法[J]. 信号处理. 2010, 26(6): 854 – 858. Liu Jianjun, Xia Shengping, Yu Wenxian. A two stage iterative procrustes matching algorithm based on SIFT feature [J]. Signal Processing, 2010, 26(6): 854 – 858. (in Chinese)
- [12] X Jiang, A Munger, H Bunke. On median graphs: properties, algorithms, and applications [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(10): 1144 – 1151.
- [13] M Everingham, L V Gool, CWilliams, JWinn, A Zisserman. Overview and results of classification challenge[A]. The PASCAL VOC'07 Challenge Workshop, in conj with ICCV [C]. Rio de Janeiro, Brazil: IEEE, 2007.
- [14] F Rothganger, S Lazebnik, C Schmid, J Ponce. 3d object modeling and recognition using local affine-invariant image descriptors and multi-view spatial constraints[J]. IJCV, 2006, 66(3): 231 – 259.
- [15] 夏胜平, 刘建军, 袁振涛, 虞华, 张乐锋, 郁文贤. 基于集群的并行分布式 RSOM 聚类[J]. 电子学报, 2007, 35(3): 385 – 391. Xia Shengping, Liu Jianjun, Yuan Zhentao, et al. Cluster-computer based invariant and distributed RSOM data-clustering[J]. Acta Electronica Sinica, 2007, 35(3): 385 – 391. (in Chinese)

作者简介



夏胜平 男, 1969 年生于湖南益阳. 国防科技大学电子科学与工程学院 ATR 实验室副教授, 博士后. 主要从事计算机视觉与目标识别方面的研究. 在国内外核心期刊和学术会议发表学术论文 80 余篇, EI 收录 50 余篇.
E-mail: xiasp1227@vip.sohu.com

宋 锐 男, 1975 年生于湖北武汉. 国防科学技术大学电子科学与工程学院 ATR 国防科技重点实验室副研究员, 博士. 主要研究方向为智能信号处理和目标识别.