

DOI: 10.7652/xjtuxb201412013

一种信任关系网络中的社团结构检测算法

杨建伟^{1,2}, 桂小林^{1,2}, 安健^{1,2}, 田丰^{1,2}

(1. 西安交通大学电子与信息工程学院, 710049, 西安; 2. 西安交通大学陕西省计算机网络重点实验室, 710049, 西安)

摘要: 针对群智计算和感知服务中不可信服务节点可能引入的安全威胁问题,提出了一种基于节点间信任关系网络的社团结构检测算法。该算法通过分析信任关系网络的功能和结构特点,引入连接的方向和权值因素,建立有向加权网络模型,定义最优路径相似度作为节点聚合标准,提出社团离散指数作为评价函数控制检测过程,从而准确识别信任关系网络中的可信节点集合,为服务节点选择提供参考。算法引入节点相似度阈值和归属判定指数控制社团聚合,与误分类节点再筛选环节配合,有效降低了检测过程中的节点误判概率,有针对性地设计社团离散指数作为评价函数,动态评估检测结果并调节聚合参数,保证了社团结构检测结果的准确率及合理性。实验结果表明:该算法能够有效实现信任关系网络中社团结构的检测与识别,与已有算法相比,检测准确率提高了 5.88%。

关键词: 信任关系网络;社团结构;有向加权模型;节点相似度;评价函数

中图分类号: TP393 **文献标志码:** A **文章编号:** 0253-987X(2014)12-0080-07

Community Structure Detecting in Trust Relationship Networks

YANG Jianwei^{1,2}, GUI Xiaolin^{1,2}, AN Jian^{1,2}, TIAN Feng^{1,2}

(1. School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China;
2. Shaanxi Province Key Laboratory of Computer Network, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A novel method to find the reliable node sets (community structure) in trust relationship networks between service units is proposed to deal with the problem that unreliable service nodes threaten the user security and service quality in crowd-computing service. The method introduces factors of weights and directions to construct a directed-weighted model for the trust relationship network, and defines a vertex similarity index and an evaluation function to control the clustering process. Experimental results show that the proposed method effectively detects and identifies the reliable node sets in a trust relationship network, and the detecting accuracy increases by 5.88 % compared with the existing algorithms.

Keywords: trust relationship network; community structure; directed-weighted model; vertex similarity; evaluation function

群智计算和感知服务中,普通用户作为基本服务提供单元,通过移动互联网进行有意识或无意识的协作,完成复杂、大规模的任务,形成随时随地与

人们生活密切相关的感知服务系统^[1]。然而,在纷繁复杂的网络环境中存在着大量的安全威胁,任何不可信服务节点的引入,都会对服务质量和用户信

息安全产生负面影响。因此,如何选择可信的服务节点集合,保证用户在享受网络服务的同时尽可能避免安全威胁,支持更好的服务体验,是亟需解决的关键问题^[2]。群智计算和感知服务系统中,节点间频繁的相互协作和联系,形成了基于节点间相互信任关系的网络结构,即信任关系网络。通过对信任关系网络建模并进行聚类分析,可以有效识别其中存在的相互间具有较高信任程度的节点簇即社团结构,据此可以在网络中针对特定用户确定服务节点候选集合,隔绝服务选择过程中的不可信节点,减少安全威胁,保证网络服务的质量和安全。

社团结构作为复杂网络中广泛存在的一项基本特性^[3],其本质是网络中存在的多个内部连接紧密而外部连接稀疏的簇。现有复杂网络社团结构检测算法大致可归纳为两类^[4]:格文纽曼(Girvan Newman, GN)^[5]、符号网络聚类(finding and extracting communities, FEC)^[6]等启发式算法以及快速纽曼 Fast Newman^[7]、纽曼贪婪 CNM^[8]、鲁汶 BGLL^[9]等基于优化的方法。启发式算法通常基于直观的假设或经验设计启发式规则,例如 GN 和 FEC 算法分别基于识别和删除簇间连接路径的策略和马尔科夫随机游走模型设计算法的启发式规则。对于大部分网络,启发式算法能够较为快速地找到最优解或近似最优解,但无法从理论上严格保证对任何输入网络都能找到令人满意的解。此外,启发式算法通常需要借助先验知识定义递归截止条件,不具备自动识别网络社团数量的能力。基于优化的方法通过优化预定义的目标函数计算复杂网络的社团结构,其结果对于目标函数的选择较为敏感。目前的 Fast Newman^[7]、CNM^[8]、BGLL^[9]等主要算法大多是基于社团模块度 Q ^[10]进行改进和优化,而模块度 Q 的优化属于 NP 难题,算法时间复杂度高,存在分辨率问题且不能适应大规模网络。后续出现的各种改进算法大多只是围绕模块度 Q 优化问题的某些方面针对特定的应用场景进行改进。已有的无论是启发式或者基于优化的算法一般都只针对简单的非有向加权网络模型,依据网络拓扑信息计算节点或者边的相似度进行聚类。信任关系网络结构往往比较复杂,社团规模变化范围大,重叠现象严重,节点间连接的权值和方向包含丰富的结构信息,而且随着传递跳数的增加,信任程度逐步衰减。这些结构和功能特点在研究中均需予以考虑,因此,常用的简单网络模型以及相应聚类算法难以直接应用到节点信任关系网络的社团结构检测过程中。

本文针对信任关系网络的社团结构检测问题,在充分考虑信任关系网络功能和结构特点的基础上,建立有向加权网络模型,并根据目标优化的算法思想,提出了一种针对信任关系网络的社团结构检测算法 (community structure detecting algorithm in trust relationship network, CDATN)。该算法通过计算节点最优路径集、定义节点相似度来进行节点的迭代聚类,同时使用社团离散指数进行评价以优化聚类结果。实验证明,该算法在信任关系网络的社团结构检测过程中,能够克服社团规模限制,发现重叠社团,与已有算法相比表现出较高的准确率,结果与实际情况接近。

1 问题描述

信任关系网络中节点之间相互关系复杂(如图 1 所示),节点对之间的连接具有明显的方向性,即对于节点对 $v(a,b)$,连接 $e(a,b)$ 并不等同于 $e(b,a)$,而且考虑到节点之间信任程度的差别,节点间的关系权值不能再视为 0 或 1 的离散情况,需要综合各方面因素为每条连接确定合适的权值。此外,信任关系网络中,节点间信任程度随中间节点的增加而逐步衰减,即若存在节点 (a,b,c) 及两条连接 $e(a,b)$ 和 $e(b,c)$,则节点对 (a,c) 之间通过节点 b 作为中介联系的信任程度不大于 (a,b) 和 (b,c) 两者中的最小值。以往的研究工作中,网络往往被抽象成简单的非有向加权网络以简化研究模型,这些重要的网络结构信息未予以考虑。因此,在信任关系网络的研究中有必要建立有向加权模型并引入相关参数,以更加全面客观地反映信任关系网络的复杂结构。




图 1 网络模型对比

关于复杂网络的社团结构检测,研究者们已经做了大量的研究和探索,提出了众多有效的算法,但大多仅针对特定网络模型,对信任关系网络的有向加权模型并不适用。因此,需要针对信任关系网络的有向加权模型提出一种新的社团检测算法,充分考虑网络的结构和功能特点,得到准确、可靠的社团检测结果。

2 信任关系网络社团结构检测

2.1 算法模型

针对信任关系网络中以服务传递为主的功能特点及连接具有明显方向性的结构特点,分析服务传递过程中相同社团节点与不同社团节点行为间的差异,不难发现以下事实:相同社团内节点到达网络中其他可达节点的路径长度相似,不同社团内节点间这一差异较大。如图2所示,因为社团内部互连密集,从源节点到达同一社团内节点的路径长度相似,而社团间连接数量有限,从源节点所属社团到达其他社团的路径长度也相似。基于以上分析,CDATN算法通过计算节点最优路径集,提出了节点社团归属的判别标准——节点相似度 ψ 。




图2 网络社团结构示意图

节点最优路径集是指对网络中的每个节点,确定其到达网络中其余节点的“信任关系网络最短路径”,从而形成的静态路由集合。由于信任关系网络中,随着跳数的增加节点间信任程度逐步递减,普通的基于权值相加的最短路径定义不再适用,因此本文提出了基于权值相乘的信任关系网络最短路径定义。

定义1 最优路径 对网络 $G(V, E)$ 中的任意节点对 $i, j \in V$,节点 $i \rightarrow j$ 的最优路径值的计算式为

$$d_{ij} = \max\{e_{iv_0} e_{v_0 v_1} \cdots e_{v_{n-1} j}\} \quad (1)$$

通过计算每对节点之间的信任关系网络最短路径,可建立网络节点最优路径集。聚类算法大多基于节点间的距离或者相似度,而关于节点相似度或者距离的定义在不同的算法中因目标网络和应用背景而各不相同^[3]。CDATN算法中,节点的相似度假 ψ 定义为不同节点到达网络内所有其余节点的平均最短路径。因此,根据节点最优路径集,可以计算出任意两节点 a, b 之间的相似度假 $\psi_{a,b}$ 。

定义2 节点相似度假 对网络 $G(V, E)$,若节点 $A, B \in V$ 到其他任一节点的信任关系网络最短路径分

别记为 $\{d_{A,v_0}, d_{A,v_1}, d_{A,v_2}, \dots, d_{A,v_i}\}, \{d_{B,v_0}, d_{B,v_1}, d_{B,v_2}, \dots, d_{B,v_i}\}$,其中 $i \in V$,则定义节点 A, B 的相似度假为

$$\psi_{A,B} = \left(\sum_{k \neq A,B}^{k \in N} [d_{A,k} - d_{B,k}] \right)^{1/2} / (n-2) \quad (2)$$

实际网络中的社团结构是自然形成的,很难事先对其数量和规模进行精确的量化。因此,迭代聚类过程进行到何时停止,即聚类效果的评价判断是聚类算法所面临的主要挑战之一。对此,本文提出了适用于CDATN算法的节点离散度 F 及社团离散指数 D_s ,衡量聚类效果,作为算法运行截止的目标函数。

定义3 节点离散度 对算法运行过程中出现的任一社团 $\varphi = \{v_1, v_2, \dots, v_n\}$, v_i 为社团 φ 中任一节点,计算节点 v_i 的平均最优路径值记为 $\bar{d}$,若将社团 φ 视为一个样本集,各节点作为样本对其数字特征 $\bar{d}$ 求其方差,则得到节点离散度为

$$F = D \left[\sum_{j \neq v}^{j \in N} d_{i,j} / (N-1) \right] \quad (3)$$

式中: N 为网络节点数; v 为社团 φ 中任一节点; $d_{i,j}$ 表示社团 φ 中的节点 i 到达网络中其他任一节点 j 的信任关系网络最短路径值。

定义4 社团离散指数 若某次聚类过程得到的结果为 $S = \{\varphi_1, \varphi_2, \dots, \varphi_n\}$, φ_i 表示该结果中的任一社团,则由定义3可知,社团 φ_i 的节点离散度为 F_i ,将 S 视为一个样本集,各个社团作为其中的样本,对样本集数字特征 F 计算其方差,则得到该次聚类对应的社团离散指数为

$$D_s = D[F] \quad (4)$$

F 表示社团内节点间平均最短路径值的相似程度,社团内节点联系越紧密,则其节点离散度越小,节点相似度假越大,表示此社团的结构更加紧凑,内部所有节点更趋于同质化。 D_s 指数用来衡量算法检测结果的合理性,其值越大,则各社团之间的相关程度越低。联合节点离散度 F ,当 D_s 取得最优值时,得到针对网络的最佳检测划分结果。

针对已建立的信任关系网络的有向加权模型,CDATN算法社团检测的主要过程包括了以下4个基本步骤。

步骤1 选取任一无归属节点作为一个社团的核,然后并入周围与此节点有直接双向联系且权值大于网络平均权值 ϵ 的所有节点,形成初级社团;

步骤2 依次检验网络中的其余节点,若其与社团内 $\phi(\phi$ 为归属判定指数,与网络密度相关,一般取

值为目标网络的平均聚集系数)比率以上节点的节点相似度满足阈值 γ , 则将该节点并入社团, 直至所有节点检测完毕;

步骤 3 将前期并入的节点进行检验并剔除所有误判节点, 如此重复进行, 直到网络中的所有节点都至少被划入一个社团;

步骤 4 针对该次检测结果计算 D_s , 并调整相似度阈值 γ , 重新开始划分过程, 直至 D_s 指数取最大值, 输出社团检测结果。

2.2 算法有效性分析

在确定信任关系网络中节点间距离或者相似度的过程中, 考虑到网络的功能特点、节点间关系以及网络结构的特殊性, CDATN 算法中定义节点的相似度 ϕ 为不同节点到达网络内所有其他节点的平均最短路径之差, 可以较好地反映节点的异质特性, 方便对其归属情况进行判定。在社会网络中, Newman 等的研究表明, 网络中拥有共同邻居的节点之间, 相互联系的可能性远高于一般节点^[11]。由于信任关系网络中的节点也反映着用户行为, 属于社会关系网络的一种特殊场景, 因此, 算法运行过程中引入步骤 2 作为辅助判断条件, 与相似度指数阈值 γ 相结合, 进一步保证社团结构的紧凑, 降低误判节点的出现概率。

现有算法针对网络社团检测效果评价问题主要是基于优化模块度 Q 的思想。Newman 等提出的模块度 Q 函数^[11], 主要是针对无向非加权的简单网络模型, Santo 等的研究表明, 基于模块度函数 Q 优化思想发现的社团结构有一定的规模限制, 小规模社团往往被忽略^[12]。在信任关系网络中, 由于节点间属于有向加权连接, 且社团规模并不均匀, 模块度函数 Q 并不适用。因此, CDATN 算法中提出了社团离散指数 D_s 作为目标函数, 以适应这种特殊的应用需求, 对检测结果进行合理评价, 控制算法的有效运行。

为验证社团离散指数 D_s 的有效性, 分析其变化规律和限制因素, 下面对算法运行过程中社团离散指数 D_s 的变化情况进行简单的推导。假设网络 S_M 为算法运行过程中得到的某一社团, 社团 S_{M_1} 、 S_{M_2} 是对 S_M 的二次划分, S_M 中的节点个数为 L , 则社团 S_{M_1} 和 S_{M_2} 中的节点个数分别为 N 、 $L-N$ 。

设 x_i 为网络中第 i 个节点到达所有其他节点最短路径的平均值, 则根据节点离散度的定义, 社团 S_{M_1} 、 S_{M_2} 、 S_M 的节点离散度分别为

$$F_{M_1} = \sum_{i=1}^N x_i^2 / N - Q^2 / N^2 \quad (5)$$

$$F_{M_2} = \sum_{i=N+1}^L x_i^2 / (L-N) - P^2 / (L-N)^2 \quad (6)$$

$$F_M = \sum_{i=1}^L x_i^2 / L - (P+Q)^2 / L^2 \quad (7)$$

$$\text{式中: } Q = \sum_{i=1}^N x_i^2, P = \sum_{i=1}^{L-N} x_i^2。$$

基于以上假设, 可以推导得出社团 S_M 的节点离散度 F_M , 与社团 S_{M_1} 、 S_{M_2} 的节点离散度 F_{M_1} 、 F_{M_2} 的关系为

$$F_M = NF_{M_1} / L + (L-N)F_{M_2} / L + Q^2 / (NL) + P^2 / (L^2 - NL) - (P+Q)^2 / L^2 \quad (8)$$

计算每个社团中所有节点平均最短路径 x_i 的均值, 分别记为 E 、 E_1 、 E_2 , 可以得到

$$F_M = NF_{M_1} / L + (L-N)F_{M_2} / L + NE_1^2 / L + (L-N)E_2^2 / L - E^2 \quad (9)$$

假设对网络的某次划分后得到一组社团 S_1 , $S_2, \dots, S_i, \dots, S_M$, 则根据社团离散指数的定义, S_M 的社团离散指数为

$$D_s = \left(\sum_{i=1}^{M-1} F_i^2 + F_M^2 \right) / M - \left(\sum_{i=1}^{M-1} F_i + F_M \right)^2 / M^2 \quad (10)$$

式中: F_i 表示前 $M-1$ 个社团中, 第 i 个社团的节点离散度; F_M 表示第 M 个社团的节点离散度。

为了计算方便, 进一步假设前面的 $M-1$ 个社团在二次划分中结构保持不变, 而只有社团 M 被划分为 M_1 和 M_2 , 则该次划分后的社团离散指数为

$$D'_s = \left(\sum_{i=1}^{M-1} F_i^2 + F_{M_1}^2 + F_{M_2}^2 \right) / (M+1) - \left(\sum_{i=1}^{M-1} F_i + F_{M_1} + F_{M_2} \right)^2 / (M+1)^2 \quad (11)$$

根据算法设计, 社团离散指数 D_s 取得最大值时, 将得到最佳划分结果。针对上述社团结构检测过程中社团离散指数的变化 D_s 与 D'_s , 分析决定其大小关系的各影响因子可知, 表达式 $(D_s - D'_s)$ 的符号由当前社团数量、已有社团内节点数目以及节点最优路径均值等相关参数共同影响决定, 且各因子影响较为平均, 不存在明显的限制因素和局部缺陷。因此, 在有向加权网络模型中, 使用社团离散指数 D_s 作为算法的目标函数, 能够有效克服模块度 Q 作为目标函数时所引入的应用网络规模和分辨率方面的限制, 可以对 CDATN 算法运行结果进行有效评价, 合理控制算法的运行和截止。

3 实验

为验证 CDATN 算法的实际性能和效果,本节首先使用西北工业大学普适计算课题组采集的群体活动数据^[13],构造信任关系网络的有向加权模型,运行 CDATN 算法,并对检测结果进行分析。然后,使用社团结构情况已知的 Zachary 俱乐部数据集^[14],作为特殊的有向加权网络模型,运行 CDATN 算法进行检测,并将结果与 BGLL 算法^[9]进行了比较分析。

3.1 信任关系数据集实验

西北工业大学普适计算课题组的群体活动数据集,基于智能手机感知功能记录了 45 个用户的日常活动与交互信息,共 852 条相关记录。对该数据进行处理,提取有效数据节点并量化其信任关系后,构造了实验中的信任关系网络有向加权模型,如图 3 所示,该网络包含从①~⑳的 32 个节点和 142 条有向加权连接。



图 3 模拟数据集

由于现有算法较少涉及针对有向加权网络模型的处理,因此,对该数据集仅使用 CDATN 算法进行社团结构检测,并针对检测结果进行了合理性分析。算法运行过程中社团离散指数 D_s 的变化情况及最后的检测结果如图 4、图 5 所示。




图 4 社区离散指数 D_s 变化图




图 5 CDATN 算法社团检测结果

分析实验结果并结合图 6 可以看出,针对构造产生的信任关系网络使用 CDATN 算法进行社团结构检测,得到了 6 个存在重叠节点的社团,各社团的节点数量在 5~8 之间平均为 6.3,社团规模分布较为均衡,与实际情况下自然形成社团的特点较为符合。此外,由于算法设计过程中考虑了真实网络中存在的社团重叠现象,因此实验结果中可以看出,形成的各个社团之间存在不同程度的重叠现象,而社团 6 中的大部分节点与其他社团重合,也反映出了信任关系网络中活跃节点之间倾向于构成社团的现实情况,使得该算法的运行结果能更好地反映实际网络社团结构。




图 6 信任关系数据集实验结果分析

3.2 Zachary 俱乐部网络数据集实验

Zachary 俱乐部网络是 20 世纪 70 年代由 Zachary 根据美国某大学空手道俱乐部成员间的人际关系状况建立的一个网络。俱乐部管理者与俱乐部主要教师(即节点 1 和节点 33)之间针对是否提高收费这一问题的争论,导致俱乐部分裂成两部分。图 7 给出了 Zachary 俱乐部的网络结构和社团情况。

实验中,首先依然将此网络作为加权网络采用




图 7 Zachary 俱乐部网络




图 10 CDATN 算法社团检测结果

BGLL 算法进行分析。BGLL 算法是一种快速的加权网络社团凝聚算法,其运行结果如图 8 所示。采用 BGLL 方法处理,网络被划分为 4 个独立社团,实际中的社团结构被割裂,而且节点 10 和节点 29 被错误划分。




图 8 采用 BGLL 算法的社团检测结果

对 Zachary 俱乐部网络进行简单处理,将网络中的每条边都视为双向等权值的连接,并且将其权值归一化至(0,1),从而可以使用 CDATN 算法对网络进行社团结构检测。算法运行过程中,社团离散指数 D_s 的变化情况和最终划分结果如图 9、10 所示。




图 9 社区离散指数 D_s 变化图

如图 10 所示,CDATN 算法将 Zachary 俱乐部网络划分为 3 个社团,实际社团 1 被割裂,节点 32 和节点 9 被误判,此外,社团 1、3 存在重叠节点 33,

社团 1、2 存在重叠节点 3。分析网络结构可以发现,节点 33 和节点 3 与所属的两个社团均存在紧密联系,可以被认定为社团间的重叠部分。由此可以看出,CDATN 算法在保证较少误判的情况下,可以有效识别网络社团结构,检测结果与网络实际情况比较吻合。

CDATN 算法与 BGLL 方法在 Zachary 俱乐部网络数据集上的实验结果对比见表 1。

表 1 Zachary 俱乐部网络数据集实验结果对比

算法	社团数	误判数	重叠	准确率/%
CDATN	3	2	Y	79.41
BGLL	4	2	N	73.53

由表 1 可见:两种算法的实验结果中,错误划分的节点数均为 2 个;BGLL 算法将整个网络划分为了 4 个独立社团,实际中的社团均被割裂;CDATN 算法的结果中,网络被划分成了 3 个存在重叠节点的社团。经过分析对比,CDATN 算法具有更高的检测准确率,而且其检测结果也更加符合实际网络情况。

4 结 论

群智计算和感知服务中可信服务节点的选择直接影响着服务的质量和安全。本文基于服务节点间的信任关系网络,建立了有向加权网络模型,在分析一般性复杂网络社团结构检测算法的基础上,通过计算节点最优路径集,定义节点间相似度,引入社区离散指数作为目标优化函数,提出了一种信任关系网络中的社团结构检测识别算法。最后,通过分析和对比该算法对真实数据集的检测效果,验证了该算法的准确性和有效性。未来的工作将主要包括以下两个方面:继续分析研究信任关系网络功能和结构特点,优化社团结构检测过程,降低算法复杂度;探讨在可信节点集内部及外部的服务传递策略、安

全策略及节点激励措施。

参考文献:

- [1] 刘云浩. 群智感知计算 [J]. 计算机学会通讯, 2012, 8(10): 38-41.
LIU Yunhao. Mobile crowd sensing [J]. Communication of China Computer Federation, 2012, 8(10): 38-41.
- [2] AN Jian, GUI Xiaolin, ZHANG Wendong, et al. Research on social relations cognitive model of mobile nodes in internet of things [J]. Journal of Network and Computer Application, 2013, 36(2): 799-810.
- [3] 汪小帆, 李翔, 陈关荣. 复杂网络理论及其应用 [M]. 北京: 清华大学出版社, 2006: 162-191.
- [4] COSICA M, GIANNOTTI F, PEDRESCHI D. A classification for community discovery methods in complex networks [J]. Statistical Analysis and Data Mining, 2011, 4(5): 512-546.
- [5] GIRVAN M, NEWMAN M E J. Community structure in social and biological networks [J]. Proceedings of the National Academy of Science, 2002, 9(12): 7821-7826.
- [6] YANG Bo, CHEUNG W K, LIU Jiming. Community mining from signed social networks [J]. IEEE Transactions on Knowledge and Data Engineering, 2007, 19(10): 1333-1348.
- [7] NEWMAN M E J. Fast algorithm for detecting community structure in networks [J]. Physical Review: E, 2004, 69(6): 066133.
- [8] CLAUSET A, NEWMAN M E J, MOORE C. Finding community structure in very large networks [J]. Physical Review: E, 2004, 70(6): 066111.
- [9] BLONDEL V D, GUILLAUME J L, LAMBIOTTE R, et al. Fast unfolding of communities in large networks [J]. Journal of Statistical Mechanics: Theory and Experiment, 2008, 10(9): 10008.
- [10] Newman M E J. Modularity and community structure in networks [J]. Proceedings of the National Academy of the United States of America, 2006, 103(23): 8577-8582.
- [11] NEWMAN M E J, PARK J. Why social networks are different from other types of networks [J]. Physical Review: E, 2003, 68(3): 036122.
- [12] SANTO F, MARC B. Resolution limit in community detection [J]. Proceedings of the National Academy of the United States of America, 2007, 104(1): 36-41.
- [13] GUO Bin, HE Huilei, YU Zhiwen, et al. Groupme: supporting group formation with mobile sensing and social graph mining [C]//Proceedings of the 9th International Conference on Mobile and Ubiquitous Systems: Computing, Networking, and Services. Berlin, Germany: Springer, 2013: 200-211.
- [14] ZACHARY W W. An information flow model for conflict and fission in small groups [J]. Journal of Anthropological Research, 1977, 15(3): 3452-3473.

(编辑 武红江)

(上接第73页)

- [8] GRABNER H, MATAS J, VAN GOOL L, et al. Tracking the invisible: learning where the object might be [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2010: 1285-1292.
- [9] YI K M, JEONG H, HEO B. Initialization-insensitive visual tracking through voting with salient local features [C]//Proceedings of the IEEE International Conference on Computer Vision. Los Alamitos, CA, USA: IEEE Computer Society, 2013: 2912-2919.
- [10] GUO Yanwen, CHEN Ye, TANG Feng, et al. Object tracking using learned feature manifolds [J]. Computer Vision and Image Understanding, 2014, 118: 128-139.
- [11] 蔺海峰, 马宇峰, 宋涛. 基于 SIFT 特征目标跟踪算法研究 [J]. 自动化学报, 2010, 36(8): 1204-1208.
LIN Haifeng, MA Yufeng, SONG Tao. Research on object tracking algorithm based on SIFT [J]. Acta Automatica Sinica, 2010, 36(8): 1204-1208.
- [12] WANG Shu, LU Huchuan, YANG Fan, et al. Super-pixel tracking [C]//Proceedings of the International Conference on Computer Vision. Piscataway, NJ, USA: IEEE, 2011: 1323-1330.
- [13] KALAL Z, MIKOLAJCZYK K, MATAS J. Forward-backward error: automatic detection of tracking failures [C]//Proceedings of the International Conference on Pattern Recognition. Piscataway, NJ, USA: IEEE, 2010: 2756-2759.
- [14] WU Yi, LIM J, YANG M H. Online object tracking: a benchmark [C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Los Alamitos, CA, USA: IEEE Computer Society, 2013: 2411-2418.

(编辑 武红江)