

基于博弈的社会网络个性化好友推荐算法研究

杨阿桃^{1,2} 汤庸¹ 王江斌³ 李建国¹

(华南师范大学计算机学院 广州 510631)¹ (贵州师范大学数学与计算机科学学院 贵阳 550001)²
(中国科学院深圳先进技术研究院 深圳 518055)³

摘要 随着在线社会网络规模的不断扩大,在线社会网络中的用户信息过载问题成为业界关注的焦点。社会网络中实体的复杂性和社交网络结构的复杂性给社交网站中的个性化推荐带来新的研究问题和挑战。提出一种基于博弈的预测模型,利用非合作博弈进行链接预测,设计了一个通过链接预测来实现个性化推荐的算法。最后,在来自学者网 SCHOLAT 的真实数据集上进行了实验,结果证明该方法能够有效地提高推荐的准确性。

关键词 社会网络,链接预测,好友推荐,博弈论

中图分类号 TP399 文献标识码 A DOI 10.11896/j.issn.1002-137X.2015.9.036

Personalized Friends Recommendation System Based on Game Theory in Social Network

YANG A-tiao^{1,2} TANG Yong¹ WANG Jiang-bin³ LI Jian-guo¹

(School of Computer, South China Normal University, Guangzhou 510631, China)¹

(Department of Mathematics and Computer Science, Guizhou Normal University, Guiyang 550001, China)²

(Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)³

Abstract With the expansion of online social networks, the information overload problem has become one of the most critical problems in computer network analysis. However, the complexity of entities and structure of the social network bring a challenge in the personalization recommendation. In this paper, a game-theoretical approach was proposed to link prediction, and the simplest way to formalize friendship recommendation is to cast the problem as a link prediction. Finally, we compared our approach with standard local measures and demonstrated a significant performance benefit in terms of mean average precision and reciprocal rank.

Keywords Social network, Link prediction, Friends recommendation, Game theory

1 引言

随着社交网络用户规模的不断扩大,用户在社交网络中产生的信息不断增多,如何为社交网络中的个人用户推荐感兴趣的信息,解决社交网络中个人信息过载问题,成为工业界和学术界关注和研究的热点。

目前,解决信息过载问题最常用的方法是基于协同过滤的推荐方法^[1]。协同过滤推荐是基于一组喜好相同的用户进行推荐。虽然这种推荐方法在购物网站如亚马逊^[2]、淘宝网^[3]上取得了不错的成绩,但协同过滤的推荐方法是建立在对用户-项目(user-item)的历史数据进行分析的基础上提出的。协同过滤通过分析用户兴趣,在用户群中找到与目标用户兴趣相似的用户,综合这些相似用户对某一项目的评价,形成目标用户对此项目的喜好程度预测。但由于协同过滤是基于兴趣相似的,因此对于社会网络的好友推荐来说并不适合。因为社会网络代表各种社会关系,通过这些社会关系,把各种

人或组织串连起来^[4],但维持社会关系的本质并不是兴趣,而是大家曾经共事的经历,或者有将来共事的可能。如亲情关系的建立是因为有在一起共同参与的生活,或者有共同关注的亲人;同学关系的建立是因为有共同在一起学习、共同参与讨论问题的经历,有着共同的老师和学校;同事关系的建立是因为共同参与工作。这些共同参与的“事件”,让人们建立了关系,也因这些共同参与的事件,人们的关系能稳固地维系下来。但仅仅用相同兴趣作为出发点来进行好友推荐,并不全面。

社会网络与其他复杂网络相比有其特殊的属性,它是人与人因为互动而形成的相对稳定的关系体系,体现了人们之间的互动和联系。社会互动会影响人们的社会行为,而互动中就存在人与人的博弈。本文分析用户在社交网络中的交互行为,把人与人的博弈活动应用到个性化推荐中,提出一种基于博弈的链接预测模型,并根据该模型设计个性化好友推荐算法。通过在在线社交网络学者网(<http://www.scholat>。

到稿日期:2014-10-23 返修日期:2014-12-22 本文受国家高技术研究发展计划(863计划)(2013AA01A212),国家自然科学基金(61272067),广东省自然科学基金团队研究项目(S2012030006242),贵州省科学技术基金(黔科合J字[2013]2214),佛山市科技创新平台项目(2013A-G10032)资助。

杨阿桃(1978-),女,博士生,主要研究方向为社会计算、计算机协同工作,E-mail:vividyoung@gznu.edu.cn;汤庸(1964-),男,博士,教授,主要研究方向为大数据与社交网络服务;王江斌(1977-),男,博士生,主要研究方向为机器人、智能制造及企业信息化;李建国(1982-),男,博士,副教授,主要研究方向为社会网络、协同计算。

com)上的验证,证明了该个性化推荐算法可以有效提高链接预测的准确性。

2 相关工作

社会网络中的好友推荐就是让网络中没有朋友关系的节点通过推荐系统产生朋友关系。判断节点间是否有关系,就需预测链接是否存在,可以说社会网络的好友推荐实质上就是链路预测。链接预测问题作为社会网络分析的一个重要分支,已经有了可观的成就。目前社会网络中的链接预测包含两个方面的含义:一类是识别实际存在但是当前网络中并不可见的链接;另一类是预测当前网络中不存在但是未来会存在的链接^[6]。常见的链接预测算法有基于节点间相似度的链接预测^[6,7]、基于监督学习的链接预测^[8]、基于概率模型的链接预测^[9]等。

链接预测的众多方法中,最简单明了而且准确率很高的方法就是将社交网络抽象成一个拓扑图,其中节点代表社交网络中的实体,节点之间的边代表实体之间的联系,如果两个节点的相似性很高,则它们在未来发生联系的概率也会较大^[10]。基于这种假设的链接预测实际上就变成了节点相似性的度量。基于节点相似性的链接预测方法有局限性,依赖于特征指标的选取,若特征指标选取得好,则链接预测会有很高的精度。常见的特征指标包括基于节点的特征,如 CA(共同邻居)^[11]、Salton 系数^[12]、Jaccard 系数(Jaccard coefficient)^[13]、AA 系数(Adamic-Adar Index)^[14]、RA 系数(Resource Allocation Index)^[15]等,以及基于路径的特征,如 LP 指数(Local Path)^[16]、Katz^[17]等。

采用这些特征量作为节点相似性的判断指标可以很准确地确定节点的相似性,从而让链接预测的结果更加准确。但这些算法都只是考虑了网络的拓扑结构的特性,只取了社会网络某一时刻的快照,将社会网络静止化处理,忽略了社会网络的动态演变过程,没有考虑社会网络的时间属性特征以及节点属性特征。比如,CA 算法将所有共同邻居等同看待,没有区分出不同的邻居对链接预测的影响是不一样的;AA 算法和 RA 算法虽然区分了每个不同的共同邻居对链接预测的不同的影响力,但是们都只关注于共同邻居本身,而忽略了这些共同邻居之间的相互影响;Katz 算法对网络中不同路径长度的节点对的影响力进行了区分,但是它没有区分出相同路径长度的节点对链接预测的影响力。针对这些不足,本文主要从网络的动态特征和邻居间的相互影响力出发,把人与人的博弈活动应用到个性化推荐中,提出一种基于博弈的链接预测模型。

3 基于博弈的链接预测算法

好友推荐的目的是帮助用户找到好友,迅速构建用户社交图谱,形成可持续发展的网络生态圈。基于博弈的观点,个性化好友推荐问题可以描述如下:推荐能够增加用户效用函数的朋友给用户,直到不能改变该效用函数为止,即到某种平衡状态结束。效用函数^[18]来源于微观经济学,表示消费者在消费中所获得的效用与所消费的商品组合之间数量关系的函数,被用以衡量消费者从消费既定的商品组合中所获得满足的程度。把社会网络中人际关系的效用函数定义为某种心理满意度的映射,即 $u(x):satisfy(x) \rightarrow R$, x 表示个人, X 表示

人群,而平衡状态是让大家共赢的状态。用 $argmax_{x \in Xu}(x)$ 表示效用函数 u 的最大值集合,平衡状态就是 $argmax_{x \in Xu}(x)$ 。例如,在一个吸毒人群的社会网络中,吸毒的人周围有更多的吸毒者,说明这个网络能够提高吸毒者的效用函数^[19]。而效用函数的考虑是学术社交网络 ResearchGate 成功的主要原因^[20],学者们选择 ResearchGate 而不是 Facebook,是因为 Facebook 没有真正挖掘这些人的效用函数,不能满足特定人群(如学者们)在社交网络上交友的需求。

3.1 博弈模型

社会网络关注的是个体之间的互动和联系。在社会网络中,个体的行为遵循一定的规则;个体会根据“环境”和接收信息来调整自身的状态和行为。本文用图 G 来描述社会网络, $G=(V, E)$; V 表示社会网络中的节点集, E 是边集合。这里给出如下假设:(1)社会网络中有 n 个节点,这里的节点指的是人,有 e 条边,边指的是人与人之间的关系;(2)朋友关系不是对称的,即 x 愿意结交 y 的朋友,但 y 未必乐意;(3)该社会网络中,每个人都只能与他的邻居进行交流;(4)个体拥有的朋友数量越多越好。

在时间维上,将博弈的全部过程分成若干个时间间隔。假设在每个时间间隔 Δt 内,网络中的每个人最多只能调整一次个体行为状态,状态的变化取决于邻居进行交互时是否能与其结为好友。个体能采取的策略集为{愿意结为好友,不愿意结为好友}。这里社会网络中的个体 x 、个体 y 都愿意结为好友, x 、 y 的收益均为 A ; x 愿意与 y 结为好友,但是 y 不愿意与 x 为好友,则 x 的收益为 B , y 的收益为 C ,反之, x 的收益为 C , y 的收益为 B ; x 、 y 都不愿意结为好友,则 x 、 y 的收益均为 D ,这里收益值的大小为 $A > B > C > D$ 。 x 与 y 陷入僵局时所付出的代价为 α ,带来的收益为 β , $\beta > \alpha$ 。如果 x 、 y 均采用策略愿意结为好友,则他们的收益 $A = \beta$;如果两人中只有一个人愿意与另一个结为好友,则对于采用“结为好友”策略的人来说,收益为 $B = \beta - \alpha/2$,而采用“不结为好友”策略的人用收益为 $C = \beta - \alpha$;如果两个人都采用“不结为好友”策略,则他们的收益 $D = 0$ 。收益矩阵如表 1 所列。

表 1 收益矩阵

		个体 x	
		结为好友	不结为好友
个体 y	结为好友	(A, A)	(B, C)
	不结为好友	(C, B)	(D, D)

是否结交一个人为好友,个人关注的是让自己的利益最大化,所以这是一个非合作博弈。为了不失一般性,把社会网络中任意两个节点间是否会建立链接这个博弈过程用以下模型 Γ 进行描述。

$$\Gamma=(V, S, U)$$

式中, $V=\{V_1, V_2, \dots, V_n\}$ 表示社会网络 G 中节点集合; $S=\{S_1, S_2, \dots, S_n\}$ 表示 G 中所有节点的策略空间; $S_i=\{s_{i1}, s_{i2}, \dots, s_{im_i}\}$ 表示节点 V_i 的策略集,其中 m_i 为 V_i 能采用的策略数量,这里 $m_i=2$,因为对于个人来说,其只有两个策略,即要么结为好友,要么不结为好友。本文用 s_i 作为 V_i 的策略变量, $s_i(V_i)=S_1 \times S_2 \times \dots \times S_n \rightarrow R$ 为节点 V_i 的决策函数。 $s=(s_1, \dots, s_n)$ 表示一个策略组合,即图 G 中所有节点在某一个时刻 t 所选择的策略。 $U=\{u_1, u_2, \dots, u_n\}$ 为全体节点的效用函数。如前所述, $u_i=satisfy(s_i(V_i))$ 。

虽然对于个体 V_i 来说,其策略集为 S_i 。但对于 V_i 所选择策略 s_{ik} ($ik=i1, i2, \dots, im_j$) 来说, s_{ik} 是策略集 S_i 上的一个概率分布,而这个概率分布称为混合策略。对应地,把 S_i 称为纯策略,而节点 V_i 的混合策略集 P_i 定义如下:

$$P_i = \{p_i : S_i \rightarrow [0, 1] \mid \sum_{s_{ik} \in S_i} p_i(s_{ik}) = 1\}$$

其中,当 $p_i(s_{ik})=1$ 时, P_i 就成了纯策略。 $P = P_1 \times \dots \times P_n$ 表示博弈的混合策略集合。对于节点 V_i 的混合策略,定义对应的期望效用函数如下:

$$\pi_i(p) = \sum_{s_{ik} \in S_i} p_i(s_{ik}) u_i(s_{ik})$$

其中, $p_i(s_{ik}) = \prod_{V_j \in V_i} p_i(S_j)$, 而 $p = (p_1, \dots, p_n)$ 是一组给定的混合策略组合。而对于纯策略组合 $s = (s_1, \dots, s_n) \in S$ 来说,节点 V_i 的期望效用函数为:

$$u_i(s) = \sum_{i \sim j} A_{ij}(s_i, s_j)$$

其中, $i \sim j$ 表示节点 V_i 与 V_j 是邻居节点, $A_{ij} \in \mathbb{R}^{c \times c}$ 是节点 V_i 与 V_j 收益矩阵,其中 $A_{ij}(x, y)$ 为表 1 中矩阵的元素。 ω_{ij} 为 $e(V_i, V_j)$ 上的权重。结合上述两式,节点 V_i 的效用函数如下:

$$\pi_i(p) = \sum_{i \sim j} x_i^T A_{ij} x_j = \sum_{i \sim j} \omega_{ij} x_i^T x_j = \sum_{i \sim j} \omega_{ij} \sum_{k=1}^c x_i^T x_j \quad (1)$$

综上所述,社会网络中根据个人收益函数来选择是否与其他人结为好友是一个混合策略博弈。纳什在 1951 年证明了混合策略中一定存在纳什均衡点^[21],但纳什均衡点(不动点)的求解是 PPAD 问题^[22],所以本文并不求解纳什均衡点,因为博弈论从来没有对博弈过程进行过合适的描述,只对可能的结果做了预测,只有理论上的存在性。本文中采用局部优化的方式来提高节点收益,向不动点靠近。

3.2 个性化推荐算法

虽然收益由具体的决策产生,但本文中定义的收益函数与节点重要性有关,需要考虑节点本身的特性。文献[23]利用外部激励的博弈和社交网络提高分享率,但忽视了分享者自身的特点,从而对提高个性化服务帮助不大,只有真正了解使用者内心的效用函数才更加有效,否则一个共享者为了博弈和控制会分享更多与自己无关的信息,产生许多“虚假”数据。

本文以节点重要性的差来决定收益函数的大小。首先需要评价一个节点相对于其它节点的重要性,如果和一个节点有连接就会有一个权重 ω_{ij} (重要性差值)在这条边上。对于一个节点 V_i ,与他相邻的节点(朋友的朋友 V_j)的权重如果很高,那么它和它成为朋友后的收益很大,而 V_j 相对来说却没有什收益,所以 V_j 不会乐意与 V_i 结为好友,所以差异大的两个节点基本也很难成为朋友;如果权重相当,差值很小,差别小,两个人的收益都能提高,这样会更容易结成“朋友”。

在社会网络中,每个节点的位置和它与邻接节点的连接方式的不同决定着该节点在网络中的重要性的不同。节点的集中性越强,与它连接的节点越多;它与其它的节点交互越多,其在网络中信息流动的关键性越强,那么该节点的重要性就越强;节点在网络中越是中心,它的用户排名越靠前,越多的节点推荐它,那么该节点的重要性就越强。所以对于如何有效地衡量节点重要性,本文从节点的中心度、亲密度、关键度、用户排名几个方面建立了节点重要性的综合衡量模型。该模型不仅考虑了节点自身特征,而且还考虑了相邻节点对该节点的影响。具体定义如下:

$$I(V_i) = \lambda_1 I_d(V_i) \times \lambda_2 I_c(V_i) \times \lambda_3 I_b(V_i) \times \lambda_4 I_u(V_i)$$

$$\text{其中, } I_d(V_i) = \frac{\text{degree}(V_i)}{n}, I_c(V_i) = \frac{n}{\sum_{j=1}^n \text{distance}(V_i, V_j)},$$

$$I_b(V_i) = \sum_{j < k} \frac{\text{short path}_{jk}(V_i)}{\text{short path}_{jk}}, I_u(V_i) = (1-p) + p(\sum \frac{I_u(V_i)}{c(V_i)})$$

$I_d(V_i)$ 描述一个用户 V_i 的节点的度 $\text{degree}(V_i)$ 与节点数的关系, $I_d(V_i)$ 越高,用户就越集中。 $I_c(V_i)$ 表示用户 V_i 与用户 V_j ($i \neq j$) 互动的容易程度,用节点间的距离来衡量,距离越短,就越容易。 $I_b(V_i)$ 表示节点 V_i 在网络中的位置,如果任一两个节点 V_j 与 V_k ($k \neq i$) 的最短路径都要通过节点 V_i ,那 V_i 就是通常所说的关键点^[24]。而 $I_u(V_i)$ 是受 Page-Rank^[25] 的启发,如果在用户中,有许多的用户都认可推荐的节点,且推荐它的这些用户是有权威的,那么在网络中该节点就有较大的影响力。下面给出社会网络中计算节点重要性的算法。

算法 1 计算节点重要性

输入:节点 V_i ($i=1, 2, \dots, n$)

输出:节点 V_i 的重要性指标 $I(V_i)$

过程: $d_i=0, c_i=0$

1. For $i=1$ to n {
2. $I_d = \text{degree}(V_i)/n$
3. for $j=1$ to n {
4. $d_i = d_i + \text{distance}(i, j)$ }
5. $I_c = n/d_i$;
6. do while {
7. $c_i = c_i + \text{shortpath}_{by}(v_j, v_k, v_i) / \text{shortpath}(v_j, v_k)$;
8. } until ($j < k$)
9. $I_b = c_i$;
10. $I = \lambda_1 * I_d + \lambda_2 * I_c + \lambda_3 * I_b + \lambda_4 * I_u$

评估完节点重要性后,计算一个节点相邻节点的重要性差。在这些相邻节点之间,把差距最小的节点推荐给另一个节点,然后重复,可以得到一个合适的社交群体,直到每个人的收益函数不再发生变化,或者变化不再显著为止。具体的 GAR(Game Approach for Recommendation) 算法描述如下。

算法 2 GAR 推荐算法

输入:节点 $V_i, s_i(V_i)$

输出:为用户 V_i 推荐的好友集合 $\text{List}(V_i)$

过程:

1. $\text{List}(V_i) \leftarrow \Phi$
2. Set $M = \text{thresholds}$
3. Rank(neighbour(V_i))
4. If $I(u) > M$ then
5. Set $U_{\text{neighbour}}[] = \text{neighbour}(u)$
6. End If
7. For each $x \in U_{\text{neighbour}}[]$ do
8. If $I(V_i) - I(x) < \theta$ then
9. $\text{List}[V_i] \leftarrow \text{List}[V_i] \cup x$
10. End for

相对于重要性差相近的点,例如 $I(V_i) - I(x) < \theta$ 的两个点 V_i 和 x ,通过点 u 互相推荐为好友。而节点 u 对于这两个点 V_i 和 x 来说,效用函数会增加,同时效用函数增加会影响重要性的变化。预测两个好友重要性的变化,当变化小于某个阈值时退出,重新 Rank,如果成为好友后, ω_{ij} 需要重新计算。

这个过程在社会和经济学中并不能达到平衡点,而是会形成所谓的马太效应。所以需要到算法按照制度机制的原理

进行改进,在网络中社会影响力最大的节点要对重要性低于某一阈值的节点主动帮扶,要把低重要性的节点按照一定比例有限地推荐给高重要性的节点。推荐好友时,不能总是推荐阈值相同的,而是要有一定的差别,鼓励每一个人提高自己的重要性。

4 实验结果分析

4.1 数据集

应用自主研发的面向科研工作者的社交网络服务平台即学者网(<http://www.scholat.com>)提供的数据,对文中提到的GAR算法进行验证。抽取数据的时间跨度从2013年10月到2014年5月,共包含3078个用户,8772个用户好友关系记录,117300条注册用户互访日志记录,3295条活跃用户记录。本文对数据进行预处理,将数据集分成测试集和训练集。从2013年10月到2014年1月,将全部3078个用户作为训练集,在训练集上训练用户选择策略的概率分布、节点重要性中的4个参数。而将2014年2月到2014年5月活跃排名在前100内的用户作为测试集,评估本文提出的推荐方法的质量。只选择这100个用户是为了减少计算量,所以只计算信息比较完整、被关注度高、登录网站次数多并且频繁使用网站发布信息的用户。

4.2 实验结果和分析

虽然目前已有的推荐系统评价指标数不胜数,但到目前为止,如何客观、有效地评价推荐系统仍然是一个没有定论的问题^[26]。推荐的准确度是评价推荐方法推荐质量的一个重要评价指标。假设用户可以考察所有用户的信息,并且可以根据结交某人为好友后自己的收益函数的高低对项目进行排序,那么准确度可以定义为推荐算法的预测排名与用户实际排名的贴近程度。因此本文主要以下面两个常用的评价指标来评估基于博弈的社交网络个性化好友推荐方法的推荐质量^[27]。

- (1)前 k 个推荐项目的平均准确率 $AP@k$;
- (2)前 k 个推荐项目的查全率 $R@k$ 。

其中,将 k 分布设置为 $k=10$ 和 $k=20$ 。

令 $hits(u_i)$ 表示前 k 个推荐的好友中目标用户 u_i 点击添加为好友的个数, $n^{est}(u_i)$ 为在测试集中目标用户 u_i 自己添加好友的个数。 $R(item(u_i))$ 表示推荐给目标用户 u_i 的好友候选集合, $U(item(u_i))$ 表示在测试集中目标用户 u_i 自己所选择好友的集合,则前 k 个推荐结果的平均准确率为:

$$AP@k = \frac{\sum_i AP(u_i)}{n}$$

其中

$$AP(u_i) = \sum_k rel(k) \times P(u_i) @k$$

$$P(u_i) @k = \frac{hits(u_i)}{k}$$

$$rel(k) = \begin{cases} 1, & R(item(u_i)) \cap U(item(u_i)) \neq \Phi \\ 0, & R(item(u_i)) \cap U(item(u_i)) = \Phi \end{cases}$$

前 k 个推荐项目的查全率为:

$$R@k = \frac{\sum_i R(u_i)}{n}$$

其中, $R(u_i) = \frac{hits(u_i)}{n^{est}(u)}$ 。

将传统的CN^[11]、AA算法^[14]和本文提出的GAR算法在

数据集上进行实验,并比较预测的准确率。 $AP@k$ 评价指标和 $R@k$ 评价指标的实验结果分别如表2和表3所列。

表2 $AP@k$ 评价指标

	CN算法	AA算法	GAR算法
AP@10	0.5463	0.5412	0.5395
AP@20	0.7745	0.7717	0.7664

表3 $R@k$ 评价指标

	CN算法	AA算法	GAR算法
R@10	0.6657	0.6665	0.6965
R@20	0.7863	0.7875	0.8107

表2和表3中的每一列对应一个链接预测算法,而行数据为对应算法下得到的分数值。表中的前两个算法是共同邻居算法(CN)和AA系数算法,后一种是本文提出的基于博弈模型的链接预测算法(GAR)。

从实验结果可以看出,前 k 个推荐项目的平均准确率 ($AP@k$)、前 k 个推荐项目的查全率 ($R@k$) 都随着参数 k 值的增加而增加。而考虑了效益函数的GAR算法提供的推荐好友候选集更能满足用户在社交网络上结交朋友的需求。

结束语 本文主要针对目前信息推荐系统缺乏用户社会关系考虑的问题,提出了一种朋友关系预测的方法。实验结果表明,该方法能够明显提高用户关系类型的预测准确性。

社交网络中节点数众多,本文根据收益函数来进行链接预测,它是博弈的结果,要精确计算其值,计算量是非常大的。因而,如何提高运算效率是未来的一个研究方向。除此之外,由于效益函数的选择对于提高准确性和减少计算量至关重要,因此选择更合理的效益函数也是未来的一个研究方向。

参考文献

- [1] Goldberg D, Nichols D A, Oki B M, et al. Using collaborative filtering to weave an information tapestry[J]. Communications of The ACM, 1992, 35(12): 61-70
- [2] Linden G, Smith B, York J. Amazon.com recommendations: item-to-item collaborative filtering [J]. Internet Computing, IEEE, 2003, 7: 76-80
- [3] <http://rdc.taobao.org/>
- [4] Jamali M, Abolhassani H. Different Aspects of Social Network Analysis[C]// Web Intelligence, 2006 (WI 2006). IEEE/WIC/ACM, 2006: 66-72
- [5] 吕琳媛. 复杂网络链路预测[J]. 电子科技大学学报, 2010, 39(9): 5-39
Lv Lin-yuan. Link prediction on complex networks [J]. Journal of University of Electronic Science and Technology of China, 2010, 39(9): 5-39
- [6] Fouss F, Pirotte A, Renders J M, et al. Random-walk computation of similarities between nodes of a graph with application to collaborative recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2007, 19(3): 355-369
- [7] 张健沛, 姜延良. 一种基于节点相似性的链接预测算法[J]. 中国科技论文, 2013, 8(7): 659-662
Zhang Jian-pei, Jiang Yan-liang. A link prediction algorithm based on node similarity [J]. China Sciencepaper, 2013, 8(7): 659-662

(下转第219页)

参考文献

- [1] Shuai Dian-xun, Shuai Qing. Particle Dynamics Approach to Multi-agent Systems[C]// IEEE International Conference on Systems, Man and Cybernetics, 2006; 2470-2475
- [2] De Giacomo G, Patrizi F. Automatic behavior composition synthesis[J]. Artificial Intelligence, 2013, 196(3): 106-142
- [3] Re C, Res T. Coming Soon to a Lab Near You: Drag-and-Drop Virtual Worlds[J]. Science, 2011, 331(6018): 669-671
- [4] Rupert M, Li C. An Organisational Multi-agent Systems Approach for Designing Collaborative Tagging Systems[J]. Web Intelligence and Intelligent Agent Technology, 2008, 2(1): 114-117
- [5] Tang Yong-li, Li Cong-dong. Dynamic Optimized Allocation of Distributed Manufacturing Resources Based on MAS[C]// IEEE International Conference on Control and Automation, 2007: 1431-1434
- [6] Jiang Yi-chuan, Zhou Yi-feng. Task Allocation for Undependable Multiagent Systems in Social Networks[J]. IEEE Transactions on Parallel and Distributed Systems, 2013, 24(8): 1671-1681
- [7] Owliya M, Saadat M. Agent-Based Interaction Protocols and Topologies for Manufacturing Task Allocation[J]. IEEE Transactions on System, Man and Cybernetics, Systems, 2013, 43(1): 38-52
- [8] Chang Y C, Chu C P. Applying learning behavioral Petri nets to the analysis of learning behavior in Web-based learning environments[J]. Information Sciences, 2010, 180(5): 995-1009
- [9] Conte R, Castelfranchi C. Cognitive and Social Action[M]. UCL Press, London, 1995
- [10] Xiang Feng, Lau . Behavioral modeling with the new bio-inspired coordination generalized molecule model algorithm[J]. Information Sciences, 2013, 252(10): 1-19
- [11] Jiang H, Jin S, Wang C. Prediction or not? An energy-efficient framework for clustering-based data collection in wireless sensor networks[J]. IEEE Transactions on Parallel and Distributed Systems, 2011, 22(6): 1064-1071
- [12] Chenji H, Stoleru R. Toward Accurate Mobile Sensor Network Localization in Noisy Environments[J]. IEEE Transactions on Mobile Computing, 2013, 12(6): 1094-1106
- [13] Isalan M. Systems biology: A cell in a computer [J]. Nature, 2012, 488(7409): 40-41
- [14] Yun-Wei, Duan-Chanlun. Modeling on the Five Elements Theory of Traditional Chinese Medicine Based on Predicate Logic Theory[C]// International Conference on Computational Intelligence and Software Engineering, 2009: 1-4
- [15] Shehory O, Kraus S. Methods for task allocation via agent coalition formation[J]. Artificial Intelligence, 1998, 101(1/2): 165-200
-
- (上接第 194 页)
- [8] Benchettara N, Kanawati R. Supervised Machine Learning applied to Link Prediction in Bipartite Social Networks[C]// 2010 International Conference on Advances in Social Networks Analysis and Mining. New York, 2010: 326-330
- [9] Zhu J, Hong J, Hughes G. Using Markov chains for link prediction in adaptive Web sites[M]// Soft-Ware 2002; Computing in an Imperfect World. Northern Ireland 2002; 60-73
- [10] Lerman K, Intagorn S, Kang J H, et al. Using Proximity to Predict Activity in Social Networks[C]// Proceeding WWW' 12 Companion Proceedings of the 21st International Conference Companion on World Wide Web, 2012; 555-556
- [11] Kossinets G. Effects of missing data in social networks[J]. Social Networks, 2006(28): 247-268
- [12] Salton G, McGill M J. Introduction to Modern Information Retrieval [M]. McGraw-Hill, Auckland, 1983
- [13] Breese J S, Heckerman D, Kadie C. Empirical analysis of predictive algorithms for collaborative filtering[C]// Proceedings of the fourteenth conference on uncertainty in artificial intelligence (UAI-98). 1998, 43-52
- [14] Adamic L, Adar E. Friends and neighbors on the web[J]. Social Networks, 2003(25): 211-230
- [15] Jin Y D, Zhou T, Wang B H, et al. Power-law strength-degree correlation from resource-allocation dynamics on weighted networks[J]. Physical Review Letters, 2007(15): 21-29
- [16] Symeonidis P, Tiakas E, Manolopoulos Y. Transitive Node Similarity for Link Prediction in Social Networks with Positive and Negative Links[C]// Proceedings of the fourth ACM Conference on Recommender System 2010. Barcelona, Spain, ACM Press, 2010: 183-190
- [17] Aggarwal C C. Social Network Data Analytics [M]. Springer, 2011; 39-48
- [18] 彭勇行, 赵新泉. 管理决策分析[M]. 北京: 科学出版社, 2008: 46-70
Peng Yong-xing, Zhao Xin-quan. Management Decision Analysis [M]. Beijing: Science Press, 2008; 46-70
- [19] Meisel M K, Clifton A D, MacKillop J, et al. Egocentric social network analysis of pathological gambling [J]. Addiction, 2013, 108(3): 584-591
- [20] Van Noorden Richard. Online collaboration: Scientists and the social network[J]. Nature, 2014, 512(7513): 126-1299
- [21] Geckil I K, Anderson P L. Applied game theory and strategic behavior [M]. Chapman and Hall/CRC, 2009: 19-31
- [22] Daskalakis C, Goldberg P W, Papadimitriou C H. The complexity of computing a nash equilibrium[C]// Proceedings of the 38th annual ACM symposium on Theory of computing (STOC' 06). 2006; 71-78
- [23] Wu T Y, Lee W T, Guizani N, et al. Incentive mechanism for P2P file sharing based on social network and game theory[J]. Journal of Network and Computer Applications, 2014, 41: 47-55
- [24] Chen L. Corporate yield spreads and bond liquidity[R]. East Lansing; Michigan State University, 2005
- [25] Brin S, Page L. The Anatomy of a Large-scale Hyper textual Web Search Engine [J]. Computer Networks, 1998, 30: 107-117
- [26] 朱郁筱, 吕琳媛. 推荐系统评价指标综述 [J]. 电子科技大学学报, 2012, 41(2): 163-167
Zhu Yu-xiao, Lv Lin-yuan. Evaluation Metrics for Recommender Systems[J]. Journal of University of Electronic Science and Technology of China, 2012, 41(2): 163-167
- [27] Niu Shu-zi, Guo Jia-feng, Lan Yan-yan, et al. Top-k learning to rank; labeling, ranking and evaluation[C]// Proceedings of the 35th International ACM SIGIR Conference on Research and Development in Information Retrieval. Portland, Oregon, USA, 2012