

基于改进 AdaBoost 算法的复杂网络链路预测

龚追飞 魏传佳

浙江工业大学计算机科学与技术学院 杭州 310023

摘要 链路预测是复杂网络的重要研究方向,当前的链路预测算法因可利用的网络信息有限,导致预测算法的精确度受限。为了提高预测算法的性能,采用改进的 AdaBoost 算法进行链路预测。首先根据复杂网络样本建立邻接矩阵,完成样本的矩阵化处理;然后采用 AdaBoost 算法进行分类训练,通过权重投票获取预测结果;最后,考虑到复杂网络弱分类器预测正负误差分布的不均衡问题,设置权重调整因子 η 及其调整范围 $[\eta_1, \eta_2]$,并根据 η 值动态调整 AdaBoost 算法的多个弱分类器分类结果的权重,从而获得准确的链路预测结果。实验结果证明,相比其他常用网络链路预测算法及传统 AdaBoost 算法,改进的 AdaBoost 算法的预测准确率优势明显,且在节点数量较多时,其预测时间性能和其他算法的差距较小。

关键词: 复杂网络;链路预测;AdaBoost;权重调整;邻接矩阵

中图法分类号 TP391

Link Prediction of Complex Network Based on Improved AdaBoost Algorithm

GONG Zhi-fei and WEI Chuan-jia

College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China

Abstract Link prediction is an important research direction of complex networks. The accuracy of current link prediction algorithm is limited due to limited network information available. In order to improve the link prediction performance of complex network, the improved AdaBoost algorithm is used to predict the link. Firstly, according to the complex network samples, the adjacency matrix is established, and the connection relationship between network nodes is constructed. Then the AdaBoost algorithm is used for classification training, and the prediction results are obtained by weight voting. Finally, considering the imbalance of the distribution of positive and negative errors in the prediction of complex network structure, the weight readjustment factor η and its adjustment range are set $[\eta_1, \eta_2]$. The weight of multiple weak classifiers in AdaBoost algorithm is dynamically adjusted according to the value to obtain accurate link prediction results. Experiments show that, compared with other common network link prediction algorithms and traditional AdaBoost algorithm, the improved AdaBoost algorithm has obvious advantages in prediction accuracy, and when there are a large number of nodes, the difference of prediction time performance between the improved AdaBoost and other algorithms is small.

Keywords Complex network, Link prediction, AdaBoost, Weight adjustment, Adjacency matrix

随着网络时代的高速发展,接入网的节点数量攀升,网络结构更加复杂多变,节点间的数据交换频繁,结合数学方法及工具对网络结构中的节点及拓扑结构进行量化分析,为探索复杂网络的演化机制提供了有价值的数据。当前对复杂网络的研究主要集中在网络结构可视化、网络节点分类^[1-3]、网络结构重构、网络拓扑扩展链路分析、网络自组织机制等方面^[4-5]。通过网络的链路预测,可以有效分析网络拓扑结构,重构复杂网络的生成过程^[6-7],挖掘复杂网络运行的内部机制和规律。当前的社交网络用户拓展、电商客户精准营销、交通网络线路预测等都是复杂网络链路预测的典型应用^[8-10]。

当前关于复杂网络链路预测的方法较多,大致可以分为

两种类型。第一种是基于拓扑结构的链路预测算法,例如文献[11]采用共同邻居(Common Neighbors,CN)的算法来实现网络链路预测,预测效率高,算法易于实现,但是预测精度不够理想。第二种是基于机器学习的链路预测算法,例如文献[12]采用神经网络算法来完成网络链路预测,相比基于拓扑结构的经典链路预测算法,基于神经网络的预测准确度得到了大幅提升。近年来,随着计算硬件性能的提升,机器学习技术得到了快速发展。其中,基于 Boosting 集成学习的 AdaBoost 算法具有很强的学习能力,在模式识别等多分类场景中表现出了高精度的特性。因此,为了进一步提高复杂网络的链路预测准确率,本文尝试采用 AdaBoost 算法进行复杂网

到稿日期:2020-06-12 返修日期:2020-08-10

基金项目:国家自然科学基金(61773348);浙江省自然科学基金(LY17F030016)

This work was supported by the National Natural Science Foundation of China (61773348) and Natural Science Foundation of Zhejiang Province, China(LY17F030016).

通信作者:龚追飞(793688937@qq.com)

络链路预测,并在原 AdaBoost 算法的基础上进行了改进。

1 复杂网络链路预测

1.1 复杂网络的矩阵表示

复杂网络的表示方法主要有图、矩阵和文档 3 种^[13]。为了结合深度学习仿真,本文选取矩阵的复杂网络来表示。用矩阵表示复杂网络伸缩性好,表示节点和边的扩展非常方便,尤其适用于节点个数较多的情况^[14]。

下文将采用实例进行复杂网络的矩阵表示。设复杂网络有 4 个节点,无向无权重网络如图 1 所示,边结构为 [1,3], [1,4], [2,3], [2,4], [3,4]。

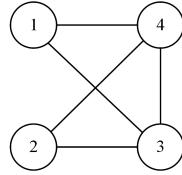


图 1 无向无权重网络

Fig. 1 Undirected and weightless network

根据邻接矩阵表示法 $A = \{a_{ij}\}_{N \times N}$, 其中 $a_{ij} = \begin{cases} 1, & (v_i, v_j) \in E \\ 0, & (v_i, v_j) \notin E \end{cases}$, 根据图 1 的结构可以得到: $a_{13} = 1, a_{14} = 1, a_{23} = 1, a_{24} = 1, a_{31} = 1, a_{32} = 1, a_{34} = 1, a_{41} = 1, a_{42} = 1, a_{43} = 1$, 其他节点的边为 0, 建立邻接矩阵结构为:

$$\begin{bmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 \\ 1 & 1 & 1 & 0 \end{bmatrix}$$

有向带权重的网络如图 2 所示,边结构带权重的分布为 [1,3,0.3], [1,4,0.8], [2,4,1.5], [3,1,0.5], [3,2,2.1], [4,2,1.7], [4,3,1.2]。

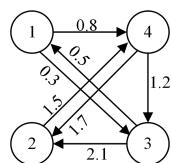


图 2 有向带权重网络

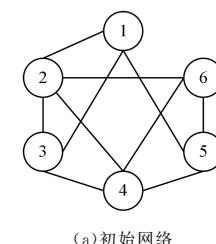
Fig. 2 Directed and weighted network

根据图 2 的结构分布,求解 a_{ij} 的值,由于网络的边带有权重,因此 a_{ij} 值不是常数 1 或 0,而是权重值,建立有向带权重网络的矩阵表示为:

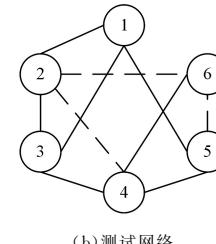
$$\begin{bmatrix} 0 & 0 & 0.3 & 0.8 \\ 0 & 0 & 0 & 1.5 \\ 0.5 & 2.1 & 0 & 0 \\ 0 & 1.7 & 1.2 & 0 \end{bmatrix}$$

1.2 链路预测

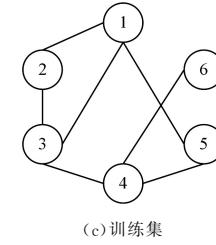
链路预测主要是根据现有的网络结构对未知的网络链路进行预测,从而拓展网络结构^[15-16],下文以无向复杂网络为基础,以图示的方式简单介绍网络链路预测原理,如图 3 所示。



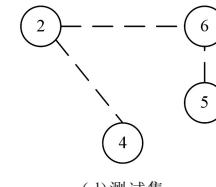
(a) 初始网络



(b) 测试网络



(c) 训练集



(d) 测试集

图 3 链路预测示意图

Fig. 3 Schematic diagram of link prediction

当前图 3 所示的网络结构共包含 6 个节点,从初始网络拓扑图中选取 3 条链路作为测试链路,如图 3(d)所示,根据图 3(c)的网络结构关系进行预测,预测节点 [2,4], [2,6], [5,6] 的链路关系。根据测试集和不存在集可以检验链路预测的性能,良好的预测性能既能够预测出测试集的链路,又能够避免不存在集。

2 改进 AdaBoost 算法的复杂网络链路预测

2.1 AdaBoost 算法的数学描述

设样本集合 $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$, $x_i \subseteq R^n$, n 表示样本维度, $y_i \in \{-1, 1\}$, 对于进入 AdaBoost 分类器的样本集权重表示为^[17]:

$$D_i = (\omega_{1i}, \omega_{2i}, \dots, \omega_{ni}, \dots, \omega_{Ni}) \quad (1)$$

其中, $i = 1, 2, \dots, N$, 共计 N 个样本, ω 表示权重, 初值设 $\omega_{1i} = \frac{1}{N}$ 。

经过迭代,根据标签计算分类错误率 e_m 。

$$e_m = P(G_m(x_i) \neq y_i) = \sum_{i=1}^N \omega_{mi} I(G_m(x_i) \neq y_i) \quad (2)$$

根据式(2)迭代 m 次后进行权重投票,每个分类器投票权重为 a_m ^[18]:

$$a_m = \frac{1}{2} \log \frac{1 - e_m}{e_m} \quad (3)$$

在迭代过程中需要不断地更新权重, D_{m+1} 表示第 $m+1$ 次迭代后得到的权重集合, 求解方法如式(4)所示^[19]:

$$D_{m+1} = (\omega_{m+1,1}, \omega_{m+1,2}, \dots, \omega_{m+1,i}, \dots, \omega_{m+1,N}) \quad (4)$$

$$\omega_{m+1,i} = \frac{\omega_{mi}}{Z_m} \exp(-a_m y_i G_m(x_i)), i=1, 2, \dots, N \quad (5)$$

根据各弱分类器得到的结果, 采用投票机制进行分类。

$$Z_m = \sum_{i=1}^M \omega_{mi} \exp(-a_m y_i G_m(x_i)) \quad (6)$$

最后获得的分类结果^[20]如下:

$$f(x) = \sum_{m=1}^M a_m G_m(x) \quad (7)$$

$$G(x) = \text{sgn}(f(x)) \quad (8)$$

2.2 AdaBoost 算法的改进

在 AdaBoost 算法过程中, 由于系统噪声或者样本清洗不干净, 导致经过多次弱分类之后的误差不断累积^[21-22], 而且这种累积会影响最后的权重投票, 因此, 为了解决因误差不断累积而造成最终预测结果不准确的问题, 对弱分类器的误差进行了权重调整。根据式(2)可以计算分类的误差, 误差值可以分为正误差和负误差, 那么可以根据式(9)和式(10)分别求解第 i 次训练的正负误差。

$$\epsilon^+ = \sum_i \omega_i (h_j(x_i) \neq y_i, y_i = 1) \quad (9)$$

$$\epsilon^- = \sum_i \omega_i (h_j(x_i) \neq y_i, y_i = -1) \quad (10)$$

然后, 计算第 i 次训练后的总误差:

$$\epsilon_i = \epsilon^+ + \epsilon^- = \sum_i \omega_i (h_j(x_i) \neq y_i) \quad (11)$$

设 $y_i = 1$ 的样本被错误分类的数量为 k^+ , $y_i = -1$ 的样本被错误分类的数量为 k^- , 可以分别求解 $y_i = 1$ 和 $y_i = -1$ 样本的误差均值:

$$\bar{\epsilon}^+ = \frac{\epsilon^+}{k^+} \quad (12)$$

$$\bar{\epsilon}^- = \frac{\epsilon^-}{k^-} \quad (13)$$

计算 $y_i = 1$ 和 $y_i = -1$ 时的误差均值比例, 如式(14)所示:

$$\eta = \frac{\bar{\epsilon}^+}{\bar{\epsilon}^-} = \frac{\epsilon^+ \times k^-}{\epsilon^- \times k^+} \quad (14)$$

其中, η 表示权重调整因子, 令 η 的可调边界分别为 η_1, η_2 , 两者的取值范围为 $\eta_1 \in [0.5, 1.0], \eta_2 \in (1.0, 1.5]$ 。若 $\eta > \eta_2$, 则分类误差集中在 $y_i = 1$ 样本这边, 需要将错分为正的样本的权重 ω 增大; 若 $\eta < \eta_1$, 则误差集中在 $y_i = -1$ 这边, 需要将错分为负的样本的权重 ω 增大^[23], 具体方法如下:

$$\omega = (1 + \zeta) \cdot \omega \quad (15)$$

其中, ζ 为权重 ω 的增大步长, 根据实际情况灵活设置, 一般设置为 0.1。当 $\eta_1 \leq \eta \leq \eta_2$ 时, 表示误差在允许的范围内, 控制参数 η_1 和 η_2 的范围, 调整权重值, 防止因为误差不均衡问题而带来的预测错误问题。

2.3 链路预测流程

根据 1.2 节的链路预测原理和改进的 AdaBoost 算法, 输入复杂网络的数据样本, 经过 AdaBoost 弱分类的权重投票, 控制正负误差的权重比例, 结合测试集合和不存在边集合, 判断链路预测的性能, 当预测准确率达到设定的阈值时, 输出链路预测的结果。改进的 AdaBoost 算法的复杂网络链路预测流程如图 4 所示。

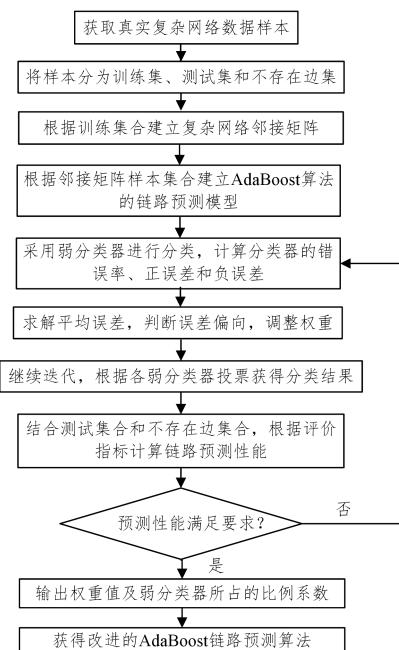


图 4 基于改进的 AdaBoost 复杂网络链路预测流程

Fig. 4 Prediction flow of complex network link based on improved AdaBoost

3 实例仿真

为了验证改进的 AdaBoost 算法对复杂网络链路预测的性能, 采用 Matlab 进行实例仿真, 通过不同层面来验证本文算法对复杂网络链路预测的有效性。

首先, 选取加利福尼亚大学的脸书社交平台上的数据进行实验, 数据集中复杂网络节点共计 20296 个, 通信记录共计 59835 条, 通过与常用复杂链路预测算法进行对比, 来验证改进的 AdaBoost 算法在复杂网络链路预测方面的性能。

3.1 不同算法的预测性能对比

3.1.1 预测准确率对比

首先设置预测准确率阈值为 0.95, 权重调整因子 $\eta_1 \in [0.5, 1.0], \eta_2 \in (1.0, 1.5]$, 选取 1800 个节点作为训练样本, 其余节点作为测试样本, 采用 Matlab 软件, 分别对共同邻居(CN)、局部路径(Local Path, LP)、卷积神经网络(Convolutional Neural Networks, CNN) 3 种常用链路预测算法及本文算法进行仿真, 算法稳定时的预测准确率如图 5 所示。

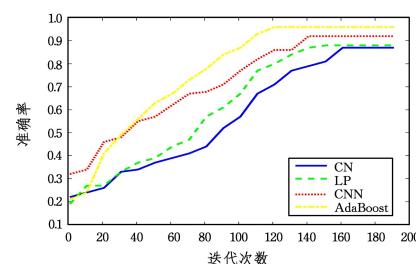


图 5 不同算法的预测准确率对比

Fig. 5 Comparison of prediction accuracy of different algorithms

从图 5 可以看出, 算法稳定时, 4 种算法对数据集 1 的复杂网络的链路预测准确率均超过了 80%, 相比而言, 改进的

AdaBoost 算法的预测准确率最高,达到了 95% 以上,CN 算法的预测性能最差。从收敛性角度来看,CN 算法训练了 180 次才趋于稳定,LP 和 CNN 算法在训练 140 次后收敛,而改进的 AdaBoost 算法在 120 次时达到了稳定,因此从收敛性方面来看,本文算法也优于其他 3 种算法。

3.1.2 不同数量样本的预测准确率和时间对比

分别从数据集的 20 296 个节点中选择 500,1 000,5 000 和 10 000 个节点组建复杂网络,然后对节点进行预测分析,预测时间和预测准确率如表 1 所列。

表 1 不同样本量的预测准确率和预测时间对比

Table 1 Comparison of prediction accuracy and prediction time with different number of samples

节点数量	算法	预测准确率/%	预测时间/s
500	CN	84.283	22
	LP	84.947	23
	CNN	89.785	47
	本文算法	95.322	41
1 000	CN	84.327	197
	LP	85.011	189
	CNN	89.612	339
	本文算法	95.412	291
5 000	CN	84.333	1 275
	LP	84.869	1 301
	CNN	89.722	1 923
	本文算法	95.331	1 739
10 000	CN	84.717	3 444
	LP	85.011	3 561
	CNN	89.671	4 718
	本文算法	95.429	3 812

从表 1 可以看出,改变节点数量,4 种算法的复杂网络链路预测准确率基本保持不变,因此预测的准确率不受节点数量的影响。但通过对比发现,本文算法的预测准确率的表现最优,均超过了 95%,CN 算法的预测准确率的表现最差。在预测时间方面,CN 算法优势明显,改变节点数量,该算法的预测时间性能均排在第一位,LP 算法的预测时间性能次之,CNN 算法最差。在节点数量小于 1 000 时,CN 算法和 LP 算法的预测时间优势明显,但随着节点数量的增加,相比本文算法,CN 和 LP 算法的预测时间优势减弱,特别是当节点数量增加到 10 000 时,预测时间性能最优的 CN 算法的预测时间为 3 444 s,而本文算法的预测时间为 3 812 s,两者的预测时间差值缩小,表明本文算法的预测时间性能得到提升。

综合而言,在预测准确率方面,不论节点数量的多少,本文算法优势明显;在预测时间方面,当节点数量较小时,本文算法没有优势,当节点数量较大时,相比其他预测算法,本文算法的预测时间的性能有所提升。

3.2 改进的 AdaBoost 算法的预测性能比较

为了进一步验证改进的 AdaBoost 算法在复杂网络链路预测方面的性能,对改进的 AdaBoost 算法进行了仿真。首先对比 AdaBoost 算法和改进的 AdaBoost 算法的预测准确率和预测时间性能;其次对权重调整因子 η 的可调边界 η_1 和 η_2 进行差异化设置,验证权重调整因子对复杂网络链路预测准确率的影响。

3.2.1 改进的 AdaBoost 算法的性能提升

从图 6 可以看出,改进的 AdaBoost 预测算法的性能优势

明显,基本保持在 95% 左右,而且不随着节点个数的增多而明显变化。

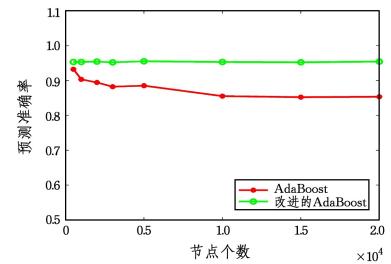


图 6 改进的 AdaBoost 预测准确率

Fig. 6 Prediction accuracy of improved AdaBoost

下面对两种算法的预测时间性能进行仿真,仿真结果如图 7 所示。

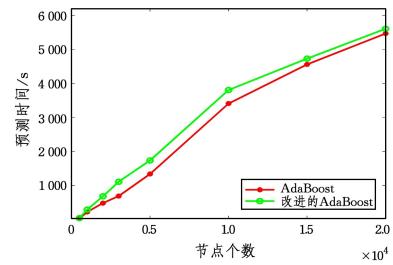


图 7 AdaBoost 和改进的 AdaBoost 预测时间的对比

Fig. 7 Prediction time comparison of AdaBoost and improved AdaBoost

从图 7 可以看出,改进的 AdaBoost 算法增加了复杂网络的链路预测时间,这主要是因为样本不均衡而带来的权重调整时间的增加。当复杂网络节点数量较少或者特别多时,两者的预测时间差距较小;当网络节点较少时,两者的预测时间值都较小;当网络节点较多时,样本的不均衡情况得到缓解,需要进行权重调整的次数也相对变少,因此两者的预测时间差距减小了;当节点个数为 [3 000,10 000] 时,两者的预测时间差距较大,这是因为这个节点数范围容易造成样本不均衡,从而导致权重调整次数变多。

3.2.2 不同权重调整因子范围的预测准确率

为了充分验证权重限制因子对预测准确率的影响,根据 2.2 节,为了防止因为误差不均衡带来较大的预测错误, η_1 和 η_2 的取值范围为 $\eta_1 \in [0.5, 1.0], \eta_2 \in (1.0, 1.5]$,当 $\eta_1 \leq \eta \leq \eta_2$ 时,不需要进行正负误差权重调整,当 η_1 和 η_2 的差值设置较大时,正负误差权重需要调整的几率小,当 η_1 和 η_2 的差值设置较小时,正负误差权重需要调整的几率大。在训练时,根据不同的 η_1 和 η_2 的取值范围,分别进行 3 次仿真,以验证不同权重因子边界对预测准确率和 MSE 均值的影响,结果如表 2 所列。由表 2 可知,在 3 次仿真中,当 $\eta_1 = 0.7, \eta_2 = 1.3$ 时,改进的 AdaBoost 算法的复杂网络链路预测准确率最高,而且 MSE 均值小。当 $\eta_1 = 0.5, \eta_2 = 1.5$ 时,表示对 η 的限制范围较宽,预测准确率较低,原因是对 η 的限制较小,样本权重调整较少,AdaBoost 算法未得到明显改进。但当 $\eta_1 = 0.8, \eta_2 = 1.2$ 时,对 η 范围的限制严格,虽然预测准确率仍保持在 94% 以上,但是 MSE 的均值较大,预测的稳定性不高,而且对 η 的严格限制会造成频繁的权重调整,从而降低预测时间的

性能。综合而言,数据集1的复杂网络链路预测权重调整因子 η 的范围设置为[0.7,1.3]时,算法获得了较好的预测准确率性能。

表2 权重调整因子对预测准确率的影响

Table 2 Influence of weight adjustment factors on prediction

accuracy

次数	权重调整因子 边界范围	预测平均 准确率/%	MSE 均值
1	$\eta_1=0.5, \eta_2=1.5$	89.737	0.0727
	$\eta_1=0.6, \eta_2=1.4$	93.637	0.0533
	$\eta_1=0.7, \eta_2=1.3$	95.313	0.0501
	$\eta_1=0.8, \eta_2=1.2$	94.268	0.1121
2	$\eta_1=0.5, \eta_2=1.5$	89.818	0.0744
	$\eta_1=0.6, \eta_2=1.4$	93.701	0.0591
	$\eta_1=0.7, \eta_2=1.3$	95.347	0.0535
	$\eta_1=0.8, \eta_2=1.2$	94.225	0.0979
3	$\eta_1=0.5, \eta_2=1.5$	89.772	0.0753
	$\eta_1=0.6, \eta_2=1.4$	93.695	0.0599
	$\eta_1=0.7, \eta_2=1.3$	95.442	0.0521
	$\eta_1=0.8, \eta_2=1.2$	94.342	0.1014

结束语 采用改进的 AdaBoost 算法用于复杂网络的链路仿真,相比常用链路预测算法,其在预测准确率方面的优势明显。根据复杂网络结构的分布均衡问题,微调权重调整因子的区间范围,可以获得较高的预测准确率。在预测时间的性能方面,改进的 AdaBoost 算法更适合于大规模复杂网络的链路预测。后续研究将进一步在预测时间性能优化方面展开,并在权重优化调整方面多做策略研究,以缩短链路预测的时间。

参 考 文 献

- [1] ZHANG M, CHEN Y. Link prediction based on graph neural networks [J]. arXiv, 2018, 9(691):1802-1807.
- [2] CHIU C, ZHAN J. Deep learning for link prediction in dynamic networks using weak estimators [J]. IEEE Access, 2018, 6(1): 35937-35945.
- [3] LI T, ZHANG J, PHILIP S Y, et al. Deep dynamic network embedding for link prediction [J]. IEEE Access, 2018, 6(1): 29219-29230.
- [4] HOU Y, HOLDER L B. Deep learning approach to link weight prediction [C] // 2017 International Joint Conference on Neural Networks. IEEE, 2017:1855-1862.
- [5] CAI L, WANG J, HE T, et al. A novel link prediction algorithm based on deepwalk and clustering method [J]. Journal of Physics: Conference Series, 2018, 1069(1):012131.
- [6] JIN D, LIU Z Y, HE R F, et al. Robust and strong explanatory community discovery method for complex networks with attributes [J]. Journal of Computer Science, 2018, 41(7):1476-1489.
- [7] PAN Y H, YU H T, WU Y. Link prediction method based on complex network dynamics model [J]. Journal of Network and Information Security, 2019(6):67-74.
- [8] WANG P, XU B W, WU Y R. Link prediction in social networks, the state-of-the-art [J]. Science China Information, 2014, 58(1):1-38.
- [9] HU W B, PENG C, LIANG H L, et al. Event detection method based on link prediction for social network evolution [J]. Journal of Software, 2015, 26(9):2339-2355.
- [10] ZHOU T, LUY L Y, ZHANG Y C. Predicting missing links via local information [J]. European Physical Journal B, 2009, 71(4): 623-630.
- [11] ZHANG Z G, LI S B, MA W L, et al. A node traversal link prediction algorithm for improving common neighborhood [J]. Minicomputer System, 2018, 39(2):207-213.
- [12] PAN Y H, YU H T, LIU S X. Link prediction algorithm based on neural network [J]. Journal of Network and Information Security, 2018, 32(7):34-42.
- [13] SCABINI L F S, CONDORI R H M, GONALVES W N, et al. Multilayer complex network descriptors for color-texture characterization [J]. Information Science, 2018, 5(1):3-10.
- [14] ALONSO L, MENDEZ-BERMUDEZ J A, CONZALEZ-MELENDRÉZ A, et al. Weighted random-geometric and random-rectangular graphs: spectral and eigenfunction properties of the adjacency matrix [J]. Journal of Complex Networks, 2018, 6(5): 753-766.
- [15] CORBELLINI A, GODOY D, MATEOS C, et al. DPM: A novel distributed large-scale social graph processing framework for link prediction algorithms [J]. Future Generation Computer Systems, 2018, 78(1):474-480.
- [16] WU J. A generalized tree augmented naive Bayes link prediction model [J]. Journal of Computational Science, 2018, 27(1):206-217.
- [17] WAND L D, XU H. Diversity analysis and improvement of AdaBoost [J]. Computer Application, 2018, 38(3):650-654.
- [18] ALSHEMARRY M S, LI Y, ABDULLA S. Ensemble of ada-boost cascades of 3L-LBPs classifiers for license plates detection with low quality images [J]. Expert Systems with Application, 2018, 92(2):216-235.
- [19] YANG Y M, CHEN X. Gait recognition method using inertial sensor and AdaBoost algorithm [J]. Computer Application Research, 2019, 36(4):258-262.
- [20] JIN L M. Infinite dimension adaBoost algorithm based on support vector machine and its application [J]. China New Communication, 2018, 20(8):208-213.
- [21] GU Y P, CHENG L S. Classification of unbalanced data based on MTS AdaBoost [J]. Computer Application Research, 2018, 3(8):346-348.
- [22] FENG X J, MA M D, WANG D Y. Face detection system based on improved adaBoost algorithm [J]. Computer Technology and Development, 2019, 29(3):89-92.
- [23] SHEN X, ZHU J H. Face detection based on skin color and improved AdaBoost algorithm [J]. Sensors and Microsystems, 2019, 38(4):149-151.



GONG Zhui-fei, born in 1977, Ph.D candidate, lecturer, senior engineer. Her main research interests include complex network and link prediction.