

异构信息网上的可达性查询

尹丹 高宏 邹兆年 李建中

(哈尔滨工业大学计算机科学与技术学院 哈尔滨 150001)

(yindan630@163.com)

Reachability Query in Heterogeneous Information Networks

Yin Dan, Gao Hong, Zou Zhaonian and Li Jianzhong

(School of Computer Science and Technology, Harbin Institute of Technology, Harbin 150001)

Abstract With the size of graph data increasing explosively, the form of graph data is much more complicated. Heterogeneous information networks can be modeled as graphs, which contain multiple types of nodes and multiple types of edges, e.g., bibliographic database, online shopping website and knowledge graphs. Reachability query in heterogeneous information networks is investigated in this paper. By using different types of relationships between nodes, query the reachability of nodes while satisfying specific path schema. This problem is polynomial. However, the time costing can't be tolerant by scanning the big network for answering one query. The existing reachability work can be classified into two categories: k-hop reachability query and label-constraint reachability query. But these techniques can't be used for processing path-based reachability query in heterogeneous information networks. Therefore, in order to respond online queries efficiently, a novel index structure is proposed, which decomposes path schemas and precomputes the reachability of nodes in sub-path schemas. Online query is efficiently computed by decomposing the query path schema and using the reachability of the indexes. A path schema decomposition strategy is developed by searching the partial order graph of path schemas in order to minimize the query time. Experiments on real world and synthetic data demonstrate the effectiveness of algorithms for reachability query in heterogeneous information networks.

Keywords heterogeneous information networks; reachability; path schema; index

摘要 随着图数据规模的爆炸式增长, 其形式也越来越复杂. 异构信息网可建模成包含多种类型的顶点和多种类型的边的图. 例如, 文献数据库、在线购物网站等. 首次研究异构信息网上的可达性查询问题. 利用不同类型顶点之间的关系, 查询两个顶点满足路径模式的可达性, 该问题的时间复杂度是多项式的. 然而在大规模的网络上, 每次查询遍历一遍网络的时间开销也是不能容忍的. 现有的可达性查询问题主要分为两类: k跳可达性查询和带有标签约束的可达性查询. 但是这两种问题的算法都不能用于解决异构信息网上的可达性查询问题. 因此, 为了实现高效的在线查询, 提出一种新的索引结构, 通过路径模式的分解, 预先计算部分路径模式的可达信息. 当在线查询到来时, 在路径模式的偏序图上, 快速找到索引结构中存在的路径子模式, 高效地计算查询结果. 在真实和人工数据集上进行了大量实验, 验证了算法的有效性.

关键词 异构信息网; 可达性; 路径模式; 索引

中图法分类号 TP311.13

基金项目: 国家重点基础研究发展计划(973计划)项目(2012CB316200); 国家自然科学基金重点项目(61033015); 国家自然科学基金重大项目(61190115, 60933001); 国家自然科学基金面上项目(61173023)

近年来,越来越多的图数据出现,如社交网络、生物网络、传感器网络和 Web 图等.与此同时,图数据的规模也成爆炸式地增长.截止 2009 年 9 月,全球最大的社交网络 facebook 已有 3 亿多个顶点,平均每个用户拥有 120 个朋友.截止 2009 年 5 月 15 日,万维网 WWW 拥有超过 3 百亿个网页,5 千亿个链接.

随着图数据规模的爆炸式增长,其形式也越来越复杂.现实世界中实体不仅仅是单纯的一种类型,很多时候多种类型的实体同时存在一个网络中,同时,联系也不仅仅存在于同一类型的实体内部,在不同类型的实体之间同样也存在着关系.异构信息网可以建模成图模型,其包含多种类型的顶点和多种类型边.文献数据库、在线购物网站、物联网等都可以看成是异构信息网.在这些网络中,顶点类型多种多样,不同类型顶点之间的连接关系也不同.

例 1. 图 1 是一个异构信息网的实例,来自互联网电影数据 IMDb. 该网络中,共有 4 种类型顶点,分别是演员(A)、电影(M)、导演(D)和电影公司(S). 其中,共存在 4 种顶点间关系,分别是演员与电影之间的参演关系、导演与电影之间的指导关系、电影与电影公司之间的投资关系以及演员之间的合作关系. 例如,Leonardo 参演了电影 Titanic 和 Inception, 其中 Titanic 的导演是 James Cameron, 该导演又指导了电影 Avatar, 同时,电影 Titanic 的投资公司是 20th Century Fox 和 Paramount.




Fig. 1 IMDb heterogeneous information network.
图 1 IMDb 异构信息网

可达性查询是检验是否存在一条路径,从一个顶点到达另一个顶点,是图分析中一个基本的操作.分析异构信息网可以得到的信息远远大于同构信息网.在异构信息网上的可达性查询可以挖掘现实世界中大量潜在的有用信息.通过不同类型顶点之间的关系,挖掘与结构有关系的顶息,进而提供有用的内在信息给用户决策.

异构信息网上基于路径可达性查询可定义为如下形式:源顶点 s , 路径 P , 目标顶点 t . 查询从 s 出发,经过路径 P 模式,是否可以到达 t .

例 2. 异构信息网上基于路径的可达性查询.

查询 1. 查询 James Cameron 是否指导由 Leonardo 参演的电影. 这个查询可以表达成异构信息网上基于路径的可达性查询,源顶点是导演 James Cameron, 目标顶点是演员 Leonardo, 路径是 ”

$D \rightarrow F \rightarrow A$ ”.

查询 2. 查询 Leonardo 与 Samuel Worthington 参演的电影是否为同一导演 James Cameron 执导. 这个查询可以表达成异构信息网上基于路径的可达性查询,源顶点是演员 Leonardo, 目标顶点是演员 Samuel Worthington, 路径是 ” $A \rightarrow F \rightarrow D \rightarrow F \rightarrow A$ ”. 在原始图中, Leonardo 与 Samuel Worthington 没有边,但是二者在路径 ” $A \rightarrow F \rightarrow D \rightarrow F \rightarrow A$ ” 上是可达的.

查询 3. 查询演员 Leonard 与 Kate Winslet 是否参演过同一部电影,此电影是由 Warner bros 公司出品. 在该查询中,源顶点是演员 Leonardo, 目标顶点是演员 Kate Winslet, 路径是 ” $A \rightarrow M \rightarrow S \rightarrow M \rightarrow A$ ”. 在原始图中, Leonardo 与 Kate Winslet 之间存在边,然而该查询中二者是不可达的,因为他们没有合作的电影是 Warner bros 出品.

异构信息网上的可达性查询反映了两个顶点在给定路径模式下是否可达,与原始图中两点间是否有边无关.原始图中两点之间有边,在给定路径模式上不一定可达.相似的,原始图中没有边的两个顶点在给定路径模式可能是可达的.不同于传统的可达性查询问题中只关于两点之间是否存在路径,异构信息网上的可达性查询问题可以深入挖掘两点的联系,对于分析和挖掘异构信息网络有重大意义.因此本文提出了异构信息网络上基于路径模式的可达性查询问题.

图上的可达性查询问题已经有很多的研究成果.但是目前还没有异构信息网上的可达性查询的研究.以往的关于可达性查询的研究工作主要集中在传统的同构图上,这些方法并不能应用到异构信息网上.同时以往工作的可达性查询大多数都是建立在有向无环图(DAG)上的,而在异构信息网上,环路是经常存在的.把强连通组件压缩成一个顶点的方法将异构信息网转化为 DAG 会丢失不同类型顶点的路径信息,因此我们无法通过传统的方法将异构信息网转化成 DAG. 这些挑战都是本文要解决的问题.

本文研究一种新类型的可达性查询,在异构信息网络上,给定源顶点和目标顶点,以及路径,查询从源顶点出发,经过给定路径模式,是否可以到达目标顶点.

本文的主要贡献总结如下:

1. 本文首次研究了异构信息网上可达性查询问题,利用不同类型顶点之间的关系,查询两个顶点间满足路径的可达性,该问题的时间复杂度是多项式的;
2. 随着网络规模爆炸式的增长,在线查询中,每个查询都遍历一遍网络的时间开销是不能容忍的.因此,为了能够快速响应在线查询,本文提出一种新的索引结构,预先计算部分路径模式的可达信息,通过路径模式的分解,共享部分子路径模式的可达信息;
3. 通过构建路径模式的偏序图,提出了贪心的路径模式选择策略,选择出部分路径模式,用于构建索引结构,计算其可达信息并存储;

4. 提出了高效的在线查询处理算法, 将查询模式分解成预计算的路径模式, 利用其可达信息, 快速的将查询结果返回给用户, 提高了在线查询效率;
5. 在真实和人工数据集上进行了大量的实验, 验证了算法的有效性.

1 相关工作

同构图上的可达性查询已经有很多研究成果, 但是现有的算法都不能应用到异构信息网络上.

最短路径查询^[1-4]只涉及两端顶点之间的最短路径, 不能区分路径经过哪类顶点. k 跳可达性查询^[5-10]是计算两点之间的最短路径是否小于等于 k , 是最短路径查询问题的扩展. 它们都无法用于挖掘异构信息网上顶点间丰富的关系.

带有标签约束的可达性查询^[11-13]是计算两点之间路径上的边的标签集合是否属于给定的标签集合. 本文研究的异构信息网上顶点的可达性要求路径上标签的顺序是预先规定的 (即路径模式), 因此无法用带标签约束的可达性问题解决本文研究的问题.

异构信息网上基于路径模式的可达性查询可以看作是特殊的子图匹配问题^[14-16]. 然而, 子图匹配问题 NP 完全的, 算法的代价高于本文研究的问题, 并不适合解决异构信息网上的可达性查询问题.

现有的异构信息网上的研究工作大多数都来自于 Sun^[17-21]. [17]搜索异构信息网中 top-k 相似对象. [18]是关于异构信息网络中的链接预测问题的研究. [22]研究了异构信息网上基于网页文本的实体识别问题. 这些都无法解决异构信息网上的可达性查询问题.

2 问题描述

定义 1. (异构信息网) 异构信息网是一个有向图 $G=(V,E,T,R,\phi,\varphi)$, 其中 V 是顶点集合, $E \subseteq V \times V$ 是边集合, T 是顶点类型集合, R 是边类型集合, $\phi: V \rightarrow T$ 是从顶点集合 V 到顶点类型集合 T 的映射函数, $\varphi: E \rightarrow R$ 是从边集合 E 到边类型集合 R 的映射函数.

图 1 是一个异构信息网实例. 现实世界中还有很多异构信息网的实例, 比如商品购物网站、多媒体分享网站等.

定义 2. (网络模式) 有向图 $T_G=(T,R)$ 是异构信息网 $G=(V,E,T,R,\phi,\varphi)$ 的模式, 其中 T 是 G 中顶点类型, 有向边集 R 是 G 中顶点之间的关系.

定义 3. (路径模式) 给定网络模式 $T_G=(T,R)$, $P=T_1 \xrightarrow{R_1} T_2 \xrightarrow{R_2} \dots \xrightarrow{R_{l-1}} T_l$ 是定义在 T_G 上的路径, T_i 是顶点类型, R_i 是从 T_i 到 T_{i+1} 的关系. $R_1 \circ R_2 \circ \dots \circ R_{l-1}$ 定义了 T_1 到 T_l 复合关系.




Fig. 2 IMDb network schema.
图 2 IMDb 网络模式

异构信息网的网络模式给出了在异构信息网中的顶点类型和顶点间的关系. 每个异构信息网是其网络模式的一个实例. 如图 2 是图 1 所示的 IMDb 网的网络模式, 图 1 是图 2 的一个实例.

异构信息网上的路径 $p = a_1 \xrightarrow{r_1} a_2 \xrightarrow{r_2} \dots \xrightarrow{r_{l-1}} a_l$ 是路径模式 $P = T_1 \xrightarrow{R_1} T_2 \xrightarrow{R_2} \dots \xrightarrow{R_{l-1}} T_l$ 的实例, 当: (a) $\forall i \in \{1, 2, \dots, l\}, \phi(a_i) = T_i$; (b) $\forall i \in \{1, 2, \dots, l-1\}, \varphi((a_i, a_{i+1})) = R_i$. 为了表达方便, 本文将 $T_1 \xrightarrow{R_1} T_2 \xrightarrow{R_2} \dots \xrightarrow{R_{l-1}} T_l$ 简写成 $T_1 \rightarrow T_2 \rightarrow \dots \rightarrow T_l$. 规定路径模式 $T_1 \xrightarrow{R_1} T_2 \xrightarrow{R_2} \dots \xrightarrow{R_{l-1}} T_l$ 的长度为 $l-1$. 图 3(a)和图 3(b)分别给出 IMDb 网络模式的 2 个路径模式: 路径模式 $Actor \rightarrow Movie \rightarrow Director$ 和路径模式 $Studio \rightarrow Movie \rightarrow Studio$. 在图 1 所示的 IMDb 网络中, "Leonardo $\rightarrow$ Titanic $\rightarrow$ James Cameron" 是图 3(a)所示路径模式的一个路径实例.




Fig. 3 Examples of Path schema.

图 3 路径模式举例

定义 4. (顶点可达性) 给定异构信息网 $G=(V,E,T,R,\phi,\varphi)$, $\forall s, t \in V$, s 是源顶点, t 是目标顶点, 路径模式 $P = T_1 \rightarrow T_2 \rightarrow \dots \rightarrow T_l$, $\phi(s) = T_1$, $\phi(t) = T_l$, 路径 p 是 P 的实例, 从 s 出发经路径 p 到达 t , 定义为 $s \rightarrow_p t$.

此处我们定义异构信息网络上可达性查询的形式为 $Q=(s,t,P)$, 其中 s 是源顶点, t 是目标顶点, P 是路径模式.

异构信息网上基于路径可达性查询 (Path Reachability Query) 的问题定义:

输入: 异构信息网 $G=(V,E,T,R,\phi,\varphi)$, 可达性查询 $Q=(s,t,P)$, 其中路径模式 $P = T_1 \rightarrow T_2 \rightarrow \dots \rightarrow$




Fig.4 System framework
图 4 系统框架图

T_1 , $\phi(s) = T_1$, $\phi(t) = T_1$;

输出: $s \rightarrow_p t$ 是否成立, 若成立, 则输出 s 和 t 之间的所有路径实例。

解决 PRQ 问题最简单的方法是深度优先或广度优先搜索。从顶点 s 出发, 搜索 T_2 类型的顶点, a_2 是 s 的 P-adjacent 顶点, 若 $\phi(a_2) = T_2$, 且 $(s, a_2) \in E$ 。从 a_2 出发, 搜索 T_3 类型的顶点, 计算 a_2 的 P-adjacent 顶点。递归此过程, 直到访问完路径模式 P 上的所有路径实例。若 $s \rightarrow_p t$, 找出 s 到 t 的所有满足路径模式 P 的实例, 否则 s 到 t 不可达。

定理 1. 异构信息网上 PRQ 问题的时间复杂度是 PTIME。

证明: 异构信息网上 PRQ 问题可通过遍历一遍异构信息网上与查询中路径模式相关的顶点和边即可得到问题的解, 因此该问题时间复杂度是 $O(|V| + |E|)$, 其中 V 是顶点集合, E 是边集合, 因此 PRQ 问题的时间复杂度是 PTIME。证毕。

然而, 当网络的规模非常大时, 每种类型的顶点数量达上百万甚至更多, 边的个数更多, 遍历一遍这些顶点的时间开销非常大。这种遍历方法无法快速地响应在线查询。因此, 本文研究如何高效的处理异构信息网上的在线可达性查询。我们通过构建索引, 预先计算出部分路径模式上顶点的可达性信息, 当在线查询到来时, 通过将查询的路径模式分解, 利用预先计算的索引来快速的响应查询, 系统框架如图 4 所示。下面我们将详细介绍算法的实现过程。

3 索引构建

3.1 路径模式分解

定义 6. (路径模式偏序关系) 给定网络模式 $T_G = (T, R)$, 路径模式 $P_1 = T_i \rightarrow T_{i+1} \rightarrow \dots \rightarrow T_j$ 和路径模式 $P_2 = T_1 \rightarrow \dots \rightarrow T_i \rightarrow \dots \rightarrow T_j \rightarrow \dots \rightarrow T_l$, 其中 $1 \leq i \leq j$, $1 \leq j \leq l$ 。那么存在偏序关系 $P_1 < P_2$, 我们说 P_2 包含 P_1 或 P_1 包含于 P_2 。

由定义 6 可知偏序关系具有传递性。

定义 7. (路径模式分解) 给定异构信息网 $G = (V, E, T, R, \phi, \varphi)$ 上的路径模式 $P = T_1 \rightarrow T_2 \rightarrow \dots$

$\rightarrow T_l$, $P_1, P_2, \dots, P_k$ 是 k 个包含于 P 的路径模式, 满足 $P = P_1 \circ P_2 \circ \dots \circ P_k$ 。其中 ' $\circ$ ' 表示路径模式 P_i 中最后一个顶点类型和 P_{i+1} 中第 1 个顶点类型间关系的合成操作。同时, 定义路径模式 P 可分解成 $P_1 \circ P_2 \circ \dots \circ P_k$ 。

通过将路径模式 P 分解为其包含的若干个不相交的子路径模式, 在每个子路径模式上计算所有顶点对的可达性。当查询顶点对 s 和 t 之间经由路径模式 P 的可达性时, 其中 $\phi(s) = T_1$, $\phi(t) = T_l$ 。从 s 出发, 通过连接子路径模式上关于 s 和 t 的可达顶点对, 可得到 s 到 t 之间关于模式 P 的路径实例。

例 3. 图 5 给出一个包含 5 种类型顶点的异构信息网。对于路径模式 $P = T_1 \rightarrow T_2 \rightarrow T_3 \rightarrow T_4 \rightarrow T_5$, 一种分解方法是 $P_1 \circ P_2$, 其中 $P_1 = T_1 \rightarrow T_2$, $P_2 = T_3 \rightarrow T_4 \rightarrow T_5$ 。表 1 和表 2 分别给出了路径模式 P_1 和 P_2 上可达顶点对的路径实例。当查询源顶点是 1, 目标顶点是 22, 路径模式是 P 。我们可以利用路径模式 P 的分解子模式的可达性信息, 来得到 1 和 22 的可达性。从路径模式 P_1 的可达性信息知, 顶点 1 到 8 可达, 经过路径 $1 \rightarrow 8$, 从图 5 知顶点 8 与 T_3 类型的 14 顶点间右边。由路径模式 P_2 可达性信息知 14 到 22 可达, 经过路径 $14 \rightarrow 18 \rightarrow 22$, 那么顶点 1 到 22 可达, 经过路径 $1 \rightarrow 8 \rightarrow 14 \rightarrow 18 \rightarrow 22$ 。由此可见, 通过路径模式分解, 可以利用子路径模式的可达性信息计算查询结果, 大大减少了在线查询的计算量。




Fig. 5 An example of heterogeneous information network.
图 5 异构信息网实例

Table 1 Reachability of path schema 1
表 1 路径模式 1 的可达信息

Source	Target	Path
1	8	1 → 8
2	9	2 → 9
3	9	3 → 9
4	10	4 → 10

5	10	5 → 10
6	11	6 → 11

Table 2 Reachability of path schema 2
表 2 路径模式 2 的可达信息

Source	Target	Path
12	21	12 → 17 → 21
13	22	13 → 18 → 22
14	22	14 → 18 → 22
14	23	14 → 19 → 23
16	21	16 → 20 → 21

通过预先计算出一部分子路径模式的可达结果,可减少在线查询中每个查询的计算量,可大大提高在线的查询响应效率.由于子路径模式的可达性信息在不同查询中可以重复利用,因此我们可以构建少量路径模式的可达信息作为索引结构,进一步降低在线查询的响应时间.

3.2 路径模式选择

每个路径模式都包含多个子路径模式,其分解方法也有多种.不同的路径模式分解后共享部分子路径模式,这部分子路径模式的可达信息只需要在预计算时计算一遍,当查询到来时就不需要计算这部分信息.如果预先将所有的路径模式的可达信息进行预计算并存储,可以最快的响应查询.但是,这需要耗费的指数级的存储空间,显然是不可行的.因此我们需要选择出一部分路径模式进行索引的构建,使得在线查询计算代价最小.因此最小化查询平均查询响应时间,快速的响应在线查询.下面就详细介绍如何选择这部分子路径模式进行可达信息计算.

给定异构信息网 $G=(V,E,T,R,\phi,\varphi)$, 其路径模式可按长度划分为 l 类(假设 G 上最长的路径模式长度为 l):

$$M_1 = \{P_{11}, P_{12}, \dots, P_{|M_1|}\}$$

$$M_2 = \{P_{21}, P_{22}, \dots, P_{|M_2|}\}$$

.....

$$M_l = \{P_{l1}, P_{l2}, \dots, P_{|M_l|}\}$$

其中 $M_i (1 \leq i \leq l)$ 表示长度为 i 的路径模式集合, $|M_i|$ 表示 M_i 中路径模式的个数.

例 4. 图 6 给出一个网络模式, 其中有 6 种类型的顶点, 最长路径模式的长度为 4. 该网络模式的路径模式如下:

$$M_1 = \{P_{11}, P_{12}, P_{13}, P_{14}, P_{15}\}$$

$$M_2 = \{P_{21}, P_{22}, P_{23}, P_{24}\}$$

$$M_3 = \{P_{31}, P_{32}, P_{33}\}$$

$$M_4 = \{P_{41}\}$$

其中,

$$P_{11} = 4 \rightarrow 1; P_{12} = 1 \rightarrow 2; P_{13} = 2 \rightarrow 3;$$

$$P_{14} = 2 \rightarrow 5; P_{15} = 3 \rightarrow 6;$$

$$P_{21} = 4 \rightarrow 1 \rightarrow 2; P_{22} = 1 \rightarrow 2 \rightarrow 3;$$

$$P_{23} = 1 \rightarrow 2 \rightarrow 5; P_{24} = 2 \rightarrow 3 \rightarrow 6.$$

$$P_{31} = 4 \rightarrow 1 \rightarrow 2 \rightarrow 3; P_{32} = 1 \rightarrow 2 \rightarrow 3 \rightarrow 6;$$

$$P_{33} = 4 \rightarrow 1 \rightarrow 2 \rightarrow 5;$$

$$M_{41} = 4 \rightarrow 1 \rightarrow 2 \rightarrow 3 \rightarrow 6.$$

根据路径模式之间的偏序关系,可以得到路径模式的偏序图.




Fig. 6 An example of network schema.
图 6 网络模式实例

例 5. 图 7 是图 6 所示的异构信息网的路径模式偏序图. 该图中顶点为异构信息网络中所有的路径模式, 且路径模式按照其长度分层. 在该图中, 顶点分为 5 层, 分别是 M_0, M_1, M_2, M_3, M_4 , 其中 M_0 是长度为 0 的路径模式, 即路径模式中只含有一个顶点类型. 对于处于相邻层的两个路径模式 P_1 和 P_2 , 若存在偏序关系 $P_1 \prec P_2$, 那么在偏序图中, 存在一条有向边从 P_1 指向 P_2 . 例如 $P_{11} = 4 \rightarrow 1$, $P_{21} = 4 \rightarrow 1 \rightarrow 2$, 存在 $P_{11} \prec P_{21}$, 则有一条有向边从 P_{11} 指向 P_{21} .




Fig. 7 Partial order graph of path schemas.
图 7 路径模式偏序图

构建路径模式的偏序图大致思想如下: 异构信息网 G 和 G 上的路径模式集合 P , 首先将 P 中的路径模式按照长度划分为 $l+1$ 层(假设最长的路径模式长度为 l) $M_0, M_1, \dots, M_l$. 将 P 中的路径模式作为偏序图的顶点集合. 若相邻两层的两个路径模式存在偏序关系, 那么则有一条有向边从低层顶点指向高层顶点. 算法 1 给出构建路径模式偏序图的大致过程. 该算法的输入是异构信息网和该网络上的路径模式集合, 输出时路径模式的偏序图.

算法 1. 路径模式偏序图的构建.

输入: 异构信息网 $G=(V,E,T,R,\phi,\varphi)$ 及 G 的路径模式集 P ;

输出: 路径模式的偏序图.

1. 把路径模式集 P 中的路径模式作为偏序图的顶点;

2. 对于任意路径模式 p_1, p_2 , 满足 $|p_2| - |p_1| = 1$, 构建有向边 (p_1, p_2) ;
3. 输出偏序图.

表3给出了构建路径模式偏序图 ConPOG 算法的伪代码.

Table 3 Construct partial order graph of path schemas algorithm

表3 构建路径模式偏序图 ConPOG 算法

Algorithm 1	Construct partial order graph
Input:	A heterogeneous information network $G = (V, E, T, R, \phi, \varphi)$, the set of path schemas P ;
Output:	Partial order graph $G_p = (V_p, E_p)$.
①	Partition P into $M_0, M_1, \dots, M_l$ according to their lengths
②	$V_p = P, E_p = \emptyset$
③	for $\forall p_1 \in M_i, p_2 \in M_{i+1}, 0 \leq i \leq l-1$ do
④	if $p_1 \prec p_2$ then
⑤	$(p_1, p_2) \in E_p$
⑥	return G_p

根据路径模式的长度将路径划分为 $l+1$ 层 (假设最长的路径模式长度为 l)，其时间开销是路径模式的个数 $O(|P|)$ (第①行)。将路径模式作为偏序图的顶点，偏序图的边集初始化为空集，时间复杂度是线性的 $O(1)$ (第②行)。计算偏序图的边集，对于相邻两层的路径模式对 $p_1, p_2, p_1 \in M_i, p_2 \in M_{i+1}$ ，如果有偏序关系 $p_1 \prec p_2$ ，那么存在一条有向边从 p_1 指向 p_2 (第③~⑤行)。判断 p_1 和 p_2 是否存在偏序关系 $p_1 \prec p_2$ 的时间复杂度是路径模式 p_2 的长度，其时间复杂度为 $O(l)$ (第④行)。这个过程最多循环 $|P|^2$ 次，所以时间复杂度为 $O(l|P|^2)$ 。最后输出偏序图 (第⑥行)。综上所述，ConPOG 算法的时间复杂度为 $O(l|P|^2)$ 。

预先计算并存储所有路径模式的可达信息需要海量的存储空间，这是不可行的。因此，我们可以预先计算部分路径模式，当在线查询到来时，通过利用预计算的这部分路径模式上的顶点可达性信息，和查询中路径模式的分解，得到查询结果。下面，我们就讲详细研究如何从路径模式偏序图中选取这部分预计算的路径模式。

假设异构信息网上的可达性查询 $Q = (s, t, P)$ 中 s, t, P 都是随机选取的，符合均匀分布，那么用户的查询所选取的路径模式是等概率的。从偏序图中选取 k 个路径模式进行预计算构建索引，使在线查询的平均响应时间最短，即所有路径模式的顶点可达查询的平均计算代价最小。这个问题可由顶点覆盖问题规约过来，是 NP 完全的。因此本文针对路径模式选择问题给出贪心的选择策略。

由路径模式的偏序图可知，出度越大顶点所代表的路径模式可以被越多的路径模式所包含，预先计算这部分路径模式，可以被更多的查询利用预计算的可达信息，大大加快查询速度。同时，对于一个

路径模式的分解，其分解的子路径模式个数越少，子路径模式越长，那么计算的开销就越小。因此当偏序图中两个顶点的出度相等时，应优先选择长度长的路径模式。

算法 2 给出路径模式的选择计算算法的基本过程。该算法的输入是异构信息网和该网络上所有的路径模式，以及预计算的路径模式个数 k ，输出是 k 个路径模式上顶点的可达信息。

算法 2. 路径模式的预计算.

输入：异构信息网 $G = (V, E, T, R, \phi, \varphi)$ 及路径模式集 P ，预计算路径模式的规模 k ;

输出： k 个路径模式上的顶点可达性信息索引。

1. 由路径模式集 P 中的路径模式构建偏序图;
2. 计算偏序图中每个顶点的出度;
3. 从偏序图中贪心的选择 k 个出度最大的路径模式集 M ;

4. 对于 M 中的任意路径模式 p ，将其源顶点相同的路径实例集合构建成为高度为 $O(|p|)$ 的树结构;

5. 对于每个路径模式，为其构建索引表，将其树结构上所有从根到叶子顶点的路径插到索引表中。

表4给出了构建索引 ConIndex 算法的伪代码。

Table 4 Construct index algorithm

表4 构建索引 ConIndex 算法

Algorithm 2	Construct reachability index of path schemas
Input:	A heterogeneous information network $G = (V, E, T, R, \phi, \varphi)$, the set of path schemas P , size of indexes k ;
Output:	Reachability index of k path schemas.
①	$G_p = (V_p, E_p) \leftarrow \text{ConPOG}(G, P)$
②	for $\forall v \in V_p \setminus M_0$ do
③	Compute $\text{outdeg}(v)$
④	Sort $V_p \setminus M_0$ decreasingly by $\text{outdeg}(v) (v \in V_p \setminus M_0)$
⑤	for $\forall u, v \in V_p \setminus M_0$ and $\text{outdeg}(u) = \text{outdeg}(v)$ do
⑥	if $\text{length}(u) > \text{length}(v)$ then
⑦	<u>u is in front of v in sorting list L</u>
⑧	Select top- k nodes T from L
⑨	for $\forall (p = T_1 \rightarrow T_2 \rightarrow \dots \rightarrow T_j) \in T$ do
⑩	Initialize the all the nodes in G with <i>unfined</i>
⑪	Initialize reachability index RI of p to be NULL
⑫	for $\forall u, \phi(u) = T_1$, $\text{label}(u) = \text{unfined}$ do
⑬	Initialize path tree PT to be NULL
⑭	Assign u as the root of PT
⑮	Label u with <i>fined</i>
⑯	for $\forall w, \phi(w) = T_2$ do
⑰	if $(u, w) \in E$ then
⑱	Label w with <i>fined</i>
⑲	Assign w as the son of u
⑳	for $i=2$ to $l-1$ then
㉑	for $\forall w, \phi(w) = T_i, \forall v, \phi(v) = T_{i+1}$ do
㉒	if $\text{label}(w) = \text{fined}$ then
㉓	if $(w, v) \in E$ then
㉔	Label v with <i>fined</i>
㉕	Assign v as the son of w
㉖	Put all the path instances from root to leaves with $ p $ length of PT into RI
㉗	return RI

首先调用构建偏序图 ConPOG 算法生成路径模式偏序图，时间开销是 $O(l|P|^2)$ (第①行)。根据偏序图中顶点的出度，将长度大于 0 的路径模式降序排序，

时间复杂度为 $O(|P|)$ (第②行)。当两个路径模式出度相等时, 长度较长的路径模式排在前面, 时间复杂度为 $O(|P|)$ (第⑤~⑦行)。选择排序列表中前 k 个路径模式 T 作为要预计算可达性信息的路径模式 (第⑧行), 需要 $O(1)$ 时间。下面, 就为每个 T 中的路径模式计算可达性信息 (第⑨~⑳行)。对于 T 的路径模式 p , 初始化 G 中所有顶点为标签为 $unfined$, p 的可达信息表 RI 为空集, 时间开销为 $O(|V|)$ (第⑩~⑪行)。对于 p 中第1个顶点类型的任意顶点 u , 构建一棵以 u 为根、高度为 $O(|p|)$ 的树 PT , 用于存放所有 u 出发, 路径模式 p 上的路径实例 (第⑫~⑳行)。首先初始化 PT 为空, 把 u 作为 PT 的根, u 顶点标记为 $fined$, 时间开销为常数 $O(1)$ (第⑬~⑭行)。对于 p 中第2个顶点类型的任意顶点 w , 若存在边 (u, w) , 把 w 作为 u 的儿子插入 PT 中, 标记 w 为 $fined$, 需要时间为第1个顶点类型和第2个顶点类型之间边集合大小 $O(E(T_1, T_2))$ (第⑮~⑯行)。对于 p 中相邻两个类型顶点 $\forall w, \phi(w)=T_i, \forall v, \phi(v)=T_{i+1}$, 若 w 的标签为 $fined$ (即在树 PT 中), 若存在 $(w, v) \in E$, 那么就将 v 作为 w 的儿子插入 PT 中, 且标记 v 为 $fined$, 时间开销为 $O(E(T_2, T_3)+E(T_3, T_4)+\dots+E(T_{j-1}, T_j))$ (第⑰~⑲行)。那么第12~25行时间开销为, $O(E(T_1, T_2)+E(T_2, T_3)+\dots+E(T_{j-1}, T_j))$, 我们可以写成 $O(|E|)$ 。最后将 PT 中所有长度为 $|p|$ 的路径存放到 p 的可达信息索引中, 其时间复杂度为 $O(|V|+|E|)$ (第㉑行)。那么, 第⑨~㉑行总的时间代价为 $O(k(|V|+|E|))$ 。最后输出 k 个路径模式的可达信息索引为常数时间 (第㉒行)。因此构建索引 ConIndex 算法的时间复杂度是 $O(k(|V|+|E|))$ 。

4 在线可达性查询处理

本节介绍如何利用上一节构建的可达信息索引快速有效地响应在线的 PRQ。用户输入查询 $Q=(s, t, P)$, 其中 s 是源顶点, t 是目标顶点, P 是路径模式, 查询 s 到 t 是否存在路径实例满足路径模式 P 。若存在, 则输出所有的路径实例, 不存在则 s 到 t 经过路径模式 P 不可达。

对于一个查询的路径模式, 需要按照预计算的索引结构进行分解, 连接预计算的子路径模式可达信息, 快速的计算出 s 到 t 的可达性。下面详细描述如何根据预计算的索引结构将路径模式 P 分解。模式 P 有很多分解方法, 分解子路径模式包含的预计算路径模式越多, 且分解的子路径模式越长, 合并子路径模式的操作越少, 时间就越快, 在线响应时间就越短。因此, 在偏序图中, 我们贪心的选择 P 的预计算祖先中长度最长的子路径模式作为其分解子模式, 然后从 P 中去掉这部分子模式, 递归的进行这个过程, 直到 P 为空。最后将这些预计算的路径模式上起始顶点为 s , 目标顶点为 t 的路径实例根据原始图的边连接

起来, 就得到查询结果。这里, 需要说明的是, 偏序图的第0层是长度为0的路径模式, 即原始图中的顶点类型, 根据预计算的路径模式将 P 进行分解, 当 P 包含的子路径长度大于0的路径模式不能连接构成 P , 分解的子路径模式中就需要包含第0层顶点。

算法3给出了在线响应PRQ的大致过程。输入是异构信息网, 路径模式的偏序图, k 个路径模式的可达信息索引, 查询 $Q=(s, t, P)$, 输出是 s 到 t 经过 P 可达性。

算法3. 在线可达查询处理。

输入: 异构信息网 $G=(V, E, T, R, \phi, \varphi)$, 路径模式偏序图 $G_p=(V_p, E_p)$, k 个路径模式的可达信息索引, 查询 $Q=(s, t, P)$;

输出: $s \rightarrow_p t$ 是否成立, 若成立, 则输出 s 和 t 之间的所有路径。

1. 将 P 与 k 个路径模式匹配, 若 P 存在, 则直接输出 $s \rightarrow_p t$ 结果, 否则执行2~4步骤;

2. 查询 P 在偏序图 G_p 中的上一层祖先是否在 k 集合中, 若不存在, 再查找低一层的祖先, 直到找到一个祖先为止;

3. 对于路径模式 P 中剩下的路径模式, 执行2过程, 直至 P 为空;

4. 利用原始图信息连接所有找到的路径模式的路径实例, 得到 $s \rightarrow_p t$ 结果。

表5给出算法3具体过程的伪代码。

Table 5 Online query processing algorithm
表5 在线查询处理 OnlineQPro 算法

Algorithm 3	Online query processing
Input:	A heterogeneous information network $G=(V, E, T, R, \phi, \varphi)$, reachability indexes RI of k path schemas, partial order graph $G_p=(V_p, E_p)$, query $Q=(s, t, P)$;
Output:	$s \rightarrow_p t$.
①	Search P in k indexes
②	if $P \in \text{indexes}$ then
③	Search reachability index of P
④	return the paths with source s and target t
⑤	Initialize path schema $W \leftarrow P$
⑥	Initialize variable $i \leftarrow P -1$
⑦	Initialize sub-path schema set SP
⑧	while $i \geq 0$ do
⑨	for each path schema $U \in M_i$ do
⑩	if $U < W$ then
⑪	Search U in RI
⑫	if $U \in RI$ then
⑬	Insert U into SP
⑭	$W \leftarrow W \setminus U$
⑮	Search W in RI
⑯	$i \leftarrow i+1$
⑰	Sort SP increasingly by the first node type $U_1, U_2, \dots, U_k$;
⑱	Select path instances PI with source s from reachability index of U_1
⑲	$i \leftarrow 1$
⑳	while $i \leq k-1$ do
㉑	for $U_i = \{T_i^1, T_i^2, \dots, T_i^{ U_i }\}, U_{i+1} = \{T_{i+1}^1, T_{i+1}^2, \dots, T_{i+1}^{ U_{i+1} }\} \in SP$
㉒	do // $T_i^{ U_i } = T_{i+1}^1$
㉓	for each $p = (p_1, p_2, \dots, p_m) \in PI$ do
㉔	Delete p from PI

```

24      for each  $q = (q_1, q_2, \dots, q_n) \in U_{i+1}$  do
25          if  $(p_m, q_1) \in E$  then
26              insert  $p_1, p_2, \dots, p_m, q_1, q_2, \dots, q_n$  into  $PI$ 
27           $i \leftarrow i + 1$ 
28      for each  $Ins = (q_1, q_2, \dots, q_{|P|}) \in PI$  do
29          if  $q_{|P|} \neq t$  then
30              Delete  $Ins$  from  $PI$ 
31      return  $PI$ 

```

搜索查询中的 P 是否在索引中存在, 耗费时间 $O(k)$ (第①行). 若存在, 直接输出索引中的源点为 s , 目标顶点为 t 的路径实例, 时间复杂度为路径模式 P 的索引表大小 $O(|RI|)$ (第②~④行). 如不存在, 执行以下过程. 首先, 在偏序图上搜索 P 的预计算路径子模式 (第⑤~⑩行). 初始化变量时间开销为 $O(1)$ (第⑤~⑦行). 路径模式 P 所在层数为第 $|P|$ 层, 我们贪心的搜索 P 最长的路径子模式, 从 $|P|-1$ 层开始搜索是否有 P 的子模式在索引中, 若有模式 R 满足 $R < P$, 那么将 R 加入 P 的子模式集合 SP 中, 从 P 中去掉关于 R 的顶点类型和关系得到模式 W , 继续搜索 W 的子路径模式, 直到 W 为空集, 若 $|P|-1$ 层不存在 P 的子路径模式, 那么向上搜索 $|P|-2$ 层, 直到第 0 层, 此过程的时间复杂度是 $O(|P|)$ (第⑧~⑩行). 将 SP 中路径模式按照其第 1 个顶点类型编号升序排列 $U_1, U_2, \dots, U_k$, 那么将这 k 个路径模式连接起来就是 P . 这个过程需要 $O(|P|)$ 时间 (第⑩行). 对于 U_1 的可达信息索引表中, 搜索源顶点是 s 的路径实例集合 PI , 若 U_1 长度为 0, 那么 PI 就是 s 顶点, 其时间开销为 U_1 的索引表 RI 大小 $O(|RI|)$ (第⑪行). 从 i 等于 1 开始, 对于相邻的两个路径模式 U_i 和 U_{i+1} , PI 中的任意长度为 $|U_i|=m$ 的路径实例 $p = (p_1, p_2, \dots, p_m)$ 若在 U_{i+1} 的可达信息索引表中存在源顶点是 p_m 的路径实例 $(q_1, q_2, \dots, q_n)$ ($p_m = q_1$), 则将插入 PI 中, 这个过程的时间开销是 $O((k-1)|RI|^2)$ (假设每个索引的大小是 $|RI|$) (第⑫~⑭行). 最后将 PI 中目标顶点不是 t 的路径实例删除, 并输出 PI , 其时间开销为 $O(|PI|)$ (第⑮~⑯). 综上所述, 在线查询处理 OnlineQPro 算法的时间复杂度为 $O(|P|) + O(k|RI|^2)$. 该算法的时间开销与路径模式长度与索引大小有关.

5 实验

本节给出算法在真实和人工数据集上的实验结果. 实验环境为 Windows PC 机, Intel(R) Core i5-2400 CPU 3.1GHz, 4GB 内存. 实验运行编译环境是 Microsoft Visual Studio 2010, 编程用 C 语言实现.

5.1 实验数据集

DBLP数据集. 本文用到的数据于2008年从DBLP网站下载的数据中提取的^[17], 并由此构建了异构信息网, 形式如图8所示. 该网络包含5种类型顶点: 论文

(Paper)、作者(Author)、会议(Conference)、关键词(Terms)和领域(Field). 本文使用4个领域的相关主要会议所发表的全部论文, 这4个领域分别是: 数据库、数据挖掘、人工智能和信息检索, 相关主要会议分类如表6所示. 同时4种类型的边存在于该网络中, 它们是: 论文与作者之间的写作关系、论文与会议之间的发表关系、论文与关键词之间的所属关系和会议与领域之间的分类关系. 本文用到的数据集包含28,702位作者在他们这20个会议上所发表的全部论文28,569篇. 数据集中共含有13,575个关键词. 在该网络中, 作者与文章之间存在74,632条边、论文与会议之间存在28,569条边、论文与关键字之间存在229,187条边以及会议与领域之间的20条边.




Fig. 8 DBLP heterogeneous information network.
图8 DBLP异构信息网

Table 6 Categories of main conferences
表6 主要会议领域划分

Area	Conferences
DB	SIGMOD, VLDB, ICDE, PODS, EDBT
DM	KDD, ICDM, SDM, PKDD, PAKDD
IR	SIGIR, WWW, CIKM, ECIR, WSDM
AI	IJCAI, AAAI, ICML, CVPR, ECML

人工数据. 为了验证本文提出算法在大规模、多类型的异构信息网上的效率, 我们人工合成数据来实验验证. 实验中, 我们生成了包含20种不同类型顶点和40种不同类型的边的随机图. 首先加入两种类型顶点, 并把这两种类型相连. 然后, 每次加入一种新类型顶点, 并随机选择一种已存在的顶点类型与其相连, 直到20种类型顶点都被加入. 在20种顶点类型中, 随机选择21个不连接的顶点类型对, 将其连接, 得到20种顶点类型和40种不同类型的边. 初始化每种顶点类型包含10万个顶点, 为了保证不同类型顶点之间的连通性, 设定网络的密度定为 $\frac{|E|}{|V|} = 2$. 对于任

意两个相连的顶点类型 T_i 和 T_j , 随机选择10万个顶点对 u, v , $u \in T_i$, $v \in T_j$, 将边 (u, v) 加入到网络中. 最后得到网络共包含200万个顶点和400万条边.

5.2 DBLP 数据实验结果

本节我们从索引的构建时间、索引规模和查询响应时间 3 个方面在 DBLP 数据集上验证算法的效率. 在查询响应时间衡量上采用图上的深度优先搜索 DFS 算法作为对比算法, 从源顶点出发, 沿着路径模式上不同类型的顶点进行深度优先搜索, 找出所有源顶点到目标顶点的路径实例.




Fig. 9 Experiment results on DBLP dataset
图 9 DBLP 数据实验结果




Fig. 10 Experiment results on synthetic dataset.
图 10 人工数据实验结果

索引的构建时间. 图9(a)给出了索引构建时间的实验结果. 横轴是 k 值, 表示预计算的路径模式个数, 纵轴是索引构建的时间, 单位是秒(s). 随着 k 值的增大, 索引构建时间也增多. 在实验中, 我们考察当 k 值从3到7的索引构建时间. 由图中可以看出, 随着 k 值的增加, 索引的构建时间也增加. 这是显而易见的, 因为需要计算的路径模式增多. 当 k 值从3增加到7时, 索引的构建时间大约从0.1s增长到2.5s. 在图中可看到, 当 k 值从3增加到4, 索引的构建时间增加非常少, 当 k 值从4增加到5, 索引的构建时间突然增加很大. 这是因为实验中所用的DBLP异构信息网络中不同类型顶点的个数差异非常大, 并且不同类型顶点间的边数目差距也很大, 从而导致 k 值增加产生的非线性时间开销.

索引的规模. 图 9(b)给出在不同 k 值情况下索引的规模. 横轴是 k 值, 表示预计算的路径模式个数, 纵轴是索引规模, 单位是兆(M). 在实验中, 我们考察当 k 值从 3 到 7 的索引构建时间. 由图中可以看出, 随着 k 值的增加, 索引的规模也随着增长, 因为有更多的路径模式上的顶点可达信息需要存储. 当 k 值从 3 增加到 7 时, 索引的规模大约从 1.1M 增长到 7.6M. 由图 9(b)可以看出当 k 值由 3 变为 4, 索引的构建时间增加非常少. 这是因为增加的路径模式所对应的顶点个数少, 因此, 当 k 值由 3 变为 4 时索引的规模也增加很少. 当由 4 增加到 5 时, 索引的规模大大增加.

查询效率. 我们在 DBLP 异构信息网络上随机产生 PRQ, 考察算法在不同情况下的查询效率. 图9(c)当查询中路径模式长度不同时, 算法的查询响应时间. 横轴 $|P|$ 表示查询路径的长度, 纵轴表示查询的平均

响应时间, 黑色折线是本文算法的性能, 红色曲线是对比算法的性能曲线. 因为 DBLP 网络中路径长度最长为 3, 所以我们考察查询路径模式的长度分别为 1, 2, 3 时, 算法的在线响应时间. 实验中, 我们针对每种路径长度, 分别随机产生 1000 个 PRQ, 本文的算法中索引规模 k 取值为 5. 由图中我们可以看出, 当查询路径模式的长度 $|P|$ 从 1 增加到 3 时, 查询的响应时间大约从 0.28s 增加到 0.57s. 路径模式的长度对查询响应的的时间影响不可忽略, 因为路径模式的分解子模式增多, 需要合并的开销也变大. 同时, 本文的算法的在线查询响应时间明显小于对比算法. 因为对比算法每次都需要搜索路径模式上所有顶点类型的顶点, 当路径模式从 1 增加到 3 时, 对比算法的时间开销增加明显大于本文算法. 因为路径模式长度增加导致 DFS 的搜索时间增加, 每次查询的时间开销都增加. 对于用户大量查询, 对比算法的性能明显下降. 由图我们可以看出, 当路径模式长度为 3 时, 本文提出算法的平均响应时间对比算法小 0.2s. 图 9(d)给出算法在 k 值不同的情况下查询平均响应时间, 横轴表示 k 值, 纵轴表示查询平均响应时间, 单位是秒(s). 在实验中, 我们随机产生 1000 个查询. 由图中我们可以看出, 当 k 值增加时, 查询响应时间也随着变短. 因为索引中包含的可达信息增多, 在线查询可利用的索引信息增多, 计算量减少. 当 k 值从 3 增加到 5 时, 查询响应时间下降迅速, 当 k 值从 5 增加到 7 时, 查询响应时间下降缓慢. 这是因为当路径模式的出度相等时, 我们优先选择长度大的路径模式, 较长的路径模式可以减少查询的路径模式的分解个数, 降低计算量, 而随后增加的预计算路径模式都是长度较短的, 对于

查询模式的分解贡献小于长度较长的路径模式。

我们同时考察了偏序图的构建时间。本文构建的 DBLP 异构信息网中包含 25 个路径模式，网络的偏序图构建时间非常短，因为其网络的路径模式个数比图的规模相比很小，因此构建其偏序图非常快。

5.3 人工数据实验结果

为了衡量算法的可扩展性，我们用人工数据考察算法在大规模网络上的执行效率。与在 DBLP 真实网络上的实验相同，本节我们从三个方面衡量算法的性能。

索引的构建时间。图 10(a)给出了算法在人工数据上索引构建时间。在实验中，我们选取 k 值从 5 增加到 30，且间隔为 5 的索引构建时间实验结果。从图中我们可以看出，索引的构建的时间随着 k 值增大而增加，当 k 为 30 时，索引的构建时间大约为 60s。因为索引的构建是在查询之前完成，且只构建一次，因此这并不影响查询的效率。

索引的规模。图 10(b)给出算法在人工数据上的索引大小结果。实验中，选取与索引构建时间相同的 k 取值对比。由图中可以看出，随着 k 值的增加，索引的空间也变大，当 k 值增加到 30 时，索引的规模达到将近 50M。这与大规模的网络相比，还是很小的，且是存储空间可容忍的。索引的规模取决于所选择的路径模式的长度以及路径实例的个数，并不是网络中所有边的加和，因此与网络中总边数没有直接关系。且路径模式长的路径实例个数一定不大于其子路径模式上的路径实例个数。因此真实数据与人工数据的索引规模的比例与原始网络的规模比例没有直接关联。

查询效率。我们在人工数据上的随机产生可达性查询，考察算法的在线查询响应时间。图 10(c)给出当查询中路径模式长度不同时，算法的查询响应时间。横轴 $|P|$ 表示查询模式的长度。实验中，我们取 k 值为 10，且对于每种长度的路径模式，随机产生 5000 个 PRQ，来考察算法的在线效率。图中，红色折线表示对比算法的性能，黑色折线是本文提出的算法性能。由图中我们可以看出，与对比算法相比，本文的算法可以更快速地响应用户的在线查询。且当查询的路径长度增加时，对比算法的查询响应时间增长较快，而本文提出的方法的查询时间增加速度较慢。这是因为当路径模式增大时，路径模式可分解的子路径模式也变长，这部分子路径模式的可达信息预先存在索引中，在线查询时，算法可以直接利用这部分信息，因此就大大减少了相应的时间。当查询路径模式为 10 时，对比算法的平均响应时间达到了 3.6s，而本文的算法仅为 2.1s，每个查询提高了 1.5s，对于大规模的在线查询，这就大大提高了效率。图 10(d)给出算法在 k 值 5, 10, 15, 20, 25 和 30 时查询的平均响应时间对比结果，实验中我们随机

产生 5000 个 PRQ，用来考察算法的在线效率。由图中我们可以看出，当 k 值增加时，查询响应时间也随着变短。当 k 值由 5 增加到 20 时查询的时间下降较快，其后趋于平稳下降。因为查询的产生是随机的，因此索引中较长的路径模式对于降低查询的计算量贡献较大。当 k 值为 5 时，查询的平均响应时间为 2.8s，当 k 值增加到 30 时，查询的平均响应时间仅仅是 0.3s。这对大规模网络上的在线查询来说是非常有意义的。

6 结论

本文研究了异构信息网络上的可达性查询问题。利用不同类型顶点之间的关系，查询两个顶点间满足路径模式的可达性。提出一种新的索引结构，通过路径模式的分解，预先计算部分路径模式的可达信息。当查询到来时，在路径模式的偏序图上，快速找到索引结构中包含的路径子模式，高效计算查询结果。最后实验验证了本文提出的算法能够在大规模网络上高效响应用户在线查询。异构信息网上的可达性查询问题可以深入挖掘两点的联系，对于分析和挖掘异构信息网络有重大意义。

参考文献

- [1] R. Agrawal, A. Borgida, and H. V. Jagadish. Efficient management of transitive relationships in large data and knowledge bases [C] //Proc of ACM SIGMOD international conference on Management of Data. New York: ACM, 1989: 253–262
- [2] R. Jin, Y. Xiang, N. Ruan, and D. Fuhry. 3-hop: a high-compression indexing scheme for reachability query [C] //Proc of ACM SIGMOD international conference on Management of Data. New York: ACM, 2009: 813–826
- [3] R. Jin, Y. Xiang, N. Ruan, and H. Wang. Efficiently answering reachability queries on very large directed graphs [C] //Proc of ACM SIGMOD international conference on Management of Data. New York: ACM, 2008: 595–608
- [4] Haixun Wang, Hao He, Jun Yang, Philip S. Yu, and Jeffrey Xu Yu. Dual labeling: Answering graph reachability queries in constant time [C] //Proc of International Conference on Data Engineering. Piscataway, NJ: IEEE, 2006: 75–75
- [5] Cheng J, Shang Z, Cheng H, et al. K-reach: who is in your small world[J]. Proc of International Conference on Very Large Data Bases Endowment. New York: ACM, 2012, 5(11): 1292–1303
- [6] Cohen E, Halperin E, Kaplan H, Zwick U. Reachability and distance queries via 2-hop labels [J]. SIAM Journal on Computing, 2003, 32(5): 1338–1355

- [7] Wei F. TEDI: Efficient shortest path query answering on graphs [C] //Proc of International Conference on Management of Data. Indianapolis: ACM Press, 2010: 99-110
- [8] Cheng J, Yu JX. On-Line exact shortest distance query processing [C] //Proc of the 12th International Conference on Extending Database Technology. Saint Petersburg: ACM Press, 2009: 481-492
- [9] Xiao YH, Wu WT, Pei J, Wang W, He ZY. Efficiently indexing shortest paths by exploiting symmetry in graphs [C] //Proc of the 12th International Conference on Extending Database Technology. Saint Petersburg: ACM Press, 2009: 493-504
- [10] Cheng J, Ke YP, Chu S, etc. Efficient processing of distance queries in large graphs: a vertex cover approach [C] //Proc of International Conference on Management of Data. Scottsdale: ACM Press, 2012: 457-468
- [11] Jin R, Hong H, Wang H, et al. Computing Label-Constraint Reachability in Graph Databases [C] //Proc of ACM SIGMOD international conference on Management of Data. New York: ACM, 2010: 123-134
- [12] Jin R, Ruan N, Xiang Y, et al. Path-tree: An efficient reachability indexing scheme for large directed graphs [J]. ACM Transactions on Database Systems (TODS), 2011, 36(1): 7
- [13] Xu K, Zou L, Yu J X, et al. Answering label-constraint reachability in large graphs[C] //Proc of ACM international conference on Information and knowledge management. New York: ACM, 2011: 1595-1600
- [14] J. Cheng, J. X. Yu, B. Ding, P. S. Yu, and H. Wang. Fast graph pattern matching [C] //Proc of International Conference on Data Engineering. Piscataway, NJ: IEEE, 2008: 913-922
- [15] H. Tong, C. Faloutsos, B. Gallagher and T. Eliassi-Rad. Fast best-effort pattern matching in large attributed graphs [C] //Proc of ACM SIGKDD international conference on knowledge discovery and data mining. New York: ACM, 2007: 737-746
- [16] L. Zou, L. Chen, and M. T. Distance-join: Pattern match query in a large graph database [J]. Proc of International Conference on Very Large Data Bases Endowment. New York: ACM, 2009, 2(1): 886-897
- [17] Sun Y, Han J, Yan X, Yu P, et al. Pathsim: Meta path-based top-k similarity search in heterogeneous information networks [J]. Proc of International Conference on Very Large Data Bases Endowment. New York: ACM, 2011, 4(11): 992-1003
- [18] Sun Y, Barber R, Gupta M, et al. Co-author relationship prediction in heterogeneous bibliographic networks [C] //Proc of International Conference on advances in social networks analysis and mining. NJ: IEEE, 2011: 121-128
- [19] Sun Y, Yu Y, Han J. Ranking-based clustering of heterogeneous information networks with star network schema [C] //Proc of ACM SIGKDD international conference on Knowledge discovery and data mining, New York: ACM, 2009: 797-806
- [20] Sun Y, Han J, Zhao P, et al. RankClus: integrating clustering with ranking for heterogeneous information network analysis [C] //Proc of the 12th International Conference on Extending Database Technology: Advances in Database Technology. New York: ACM, 2009: 565-576
- [21] Sun Y, Norick B, Han J, et al. Integrating meta-path selection with user-guided object clustering in heterogeneous information networks [C] //Proc of ACM SIGKDD international conference on knowledge discovery and data mining. New York: ACM, 2012: 1348-1356
- [22] Shen W, Han J, Wang J. A probabilistic model for linking named entities in web text wit heterogeneous information networks [C] //Proc of ACM SIGMOD international conference on Management of Data. New York: ACM, 2014: 1199-1210



Yin Dan, born in 1987. PhD candidate. Her research interests include massive data management and graph database.



Gao Hong, born in 1966. Professor, PhD supervisor. Her research interests include massive data management and wireless sensor networks.



Zou Zhaonian, born in 1979. PhD, lecture. His research interests include massive data management and graph database.



Li Jianzhong, born in 1950. Professor, PhD supervisor. His research interests include massive data management and wireless sensor networks.