DOI:10.11918/j.issn.0367-6234.201711054

基于 GPS 平台的高效 k-bisimulation 计算算法

阚忠良[1], 李建中[1,2], 徐 俊[2], 王宏志[2]

(1.黑龙江大学 计算机科学技术学院,哈尔滨 150080;2.哈尔滨工业大学 计算机科学与技术学院, 哈尔滨 150001)

摘 要: 计算图的互模划分在许多应用领域中起着至关重要的作用. 图中两个点是互模的当且仅当这两点具有相同的特征. 随着图数据规模的增大,传统的运行在单机上的互模划分算法面临着越来越大的挑战,分布式算法以及并行算法则成为提高图计算可扩展性的重要途径. 最近研究人员提出两种基于 MapReduce 计算模型的分布式互模划分算法,算法均计算图的局部互模划分. 采用 MapReduce 计算模型的分布式互模划分算法具有网络通讯代价高昂的问题,每次 MapReduce 迭代操作均会将整个图中所有点边的状态通过网络传输,重新为点边分配计算节点,但实际上计算点的局部互模划分特征仅需要局部信息. 以此为研究出发点,本文提出了基于分布式图数据处理平台的互模划分算法,仅使用点的局部信息来计算其特征,进而提升计算效率. 经过实验验证,本文算法可以大幅度减少算法执行过程中的网络数据传输量. 在包含数亿边大图上的实验表明,在未经图的预处理的情况下,本文算法的时间效率提升了 7~16 倍,有效的解决了 MapReduce 计算模型带来的网络通讯代价高昂的问题.

关键词: 互模划分;k-互模划分;图处理系统;分布式算法;大数据

中图分类号: TP311 **文献标志码**: A **文章编号**: 0367-6234(2018)05-0173-12

GPS-based algorithms for efficient k-bisimulation computation

KAN Zhongliang, LI Jianzhong, XU Jun, WANG Hongzhi

(1. School of Computer Science and Technology, Heilongjiang University, Harbin 150080, China;
2. School of Computer Science and Technology, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Computing the bisimulation partition of a graph plays a key role in various application areas. Two nodes are bisimular if and only if they obtain the same signature. Faced with a big graph, traditional in-memory algorithms can hardly meet practical need. Recently, researchers have proposed two kinds of MapReduce based distributed algorithms to handle bisimulation partition on the big graph, both calculating localized bisimulation. MapReduce based algorithms suffer from huge network communication burden, at the meantime, we only need local information to calculate the signature of a node. Motivated by these observations, we propose an algorithm based on a graph processing system that only uses local information to calculate the signature of a node. We argue that our algorithm can make considerable reduction on the network transportation during computation. In the experiment calculated on the big graph which contains billions of edges, our algorithm can be seven to sixteen times faster even without graph pre-partition.

Keywords: simulation partition; k-bisimulation; graph processing system; distributed algorithms; big data

在基于图的众多研究中,互模划分在许多应用领域中都起着至关重要的作用[1]. 直观上,图的互模划分是指将图中的点按照预先定义的"特征"进行划分的操作,"特征"相同的点被划分到同一集合中. "特征"可以根据需要而灵活定义,例如它可以包含点的内容以及点在图中的位置信息.

互模划分有着广泛的应用. 在数据压缩领域[2-3],同一集合中的点使用相同的编号;通过适当的定义,互模划分可以被用来为 XML 以及 RDF 数据库建立结构化索引[4-5];此外,在数据的查询优化以及分析[6]中互模划分也有明确的应用.

随着图数据规模(点数目、边数目)的增长,许多图数据,如社交网络图等,已经包含数以亿计的点和边. 传统的运行在单机上的互模划分算法面临着越来越大的挑战,分布式算法以及并行算法则成为提高图计算可扩展性的重要途径.

针对图的互模划分(k-互模划分)问题,Luo[7]以及 Alexander Schätzle[8]分别提出基于 MapReduce 计算模型的局部互模划分算法. 这两种算法均使用 Hadoop 作为分布式数据处理平台,解决了传统算法难以胜任的在大图数据上进行互模划分的问题. Stefan Blom 等[9]提出的 the naive method 算法是一

收稿日期: 2017-11-12
基金项目: 国家科技支撑计划项目(2015BAH10F01);国家自然科学基金项目(U1509216,61472099)
作者简介: 阚忠良(1969—),男,博士研究生,副教授;
李建中(1950—),男,教授,博士生导师;
王宏志(1978—),男,教授,博士生导师
通信作者: 李建中,lijzh@hit.edu.cn.

种迭代算法,该算法的分布式版本分为多次迭代,每次迭代执行下面的三步操作:计算点的特征、为点的特征计算一个全局唯一的编号(也就是标识)、邻居点之间交换信息—为下一轮迭代做准备. Luo 以及 Schätzle 提出的算法也是采用这种思想,其中 Luo 的方法每轮迭代需要三次完整的 MapReduce 操作来完成这三步操作;而 Schätzle 的方法中则采用哈希方法获得点的特征编号,同时通过在 MapReduce 操作中直接"输出"完整的图. Hadoop 平台中数据在 Mapper 和 Reducer 之间的传输全部通过网络. 这种设计使得采用 Hadoop 平台实现的上述两种算法不可避免地会有沉重的网络数据传输任务. 采用 MapReduce 计算框架意味着计算点的 k-互模特征的时候,无差别地对待图中的每个点. 但是为计算图中点的 k-互模特征,只需要获取该点的邻居信息(与点距离为 k 以内)即可,所以图中不同的点应该被差别对待以减少不必要的通信代价.

本文算法中采用 GPS[10]/Pregel[11] 的计算模型来解决这一问题,在 GPS/Pregel 平台上图中的点通过边向相邻点传递信息,只有边的起点和终点由不同工作节点处理的情况下,数据传输需要通过网络. 这个特点有效地减少了网络数据通信量.

1 局部互模相关概念

1.1 局部互模

为便于表述,下文中采用 k - 互模来表示局部互模. k - 互模是指预先定义点的特征只包含距离它 k 以内(包含 k)的邻居信息以及点自身的信息($k \geqslant 0$).

N 表示有限的点集,$E \subseteq N \times N$ 表示边集合,λ_N 表示从点集 N 到点编号集合 Γ_N 的映射,λ_E 表示从边集 E 到边编号集合 Γ_E 的映射. k - 互模严格的数学定义如下

定义 1.1[7] k 是一个非负整数,$G = < N, E, \lambda_N, \lambda_E >$ 是一个图,那么点 $u, v \in N$ 被称为 k - 互模(表示为 $u \approx^k v$),当且仅当下述条件成立

1) $\lambda_N(u) = \lambda_N(v)$;

2) 当 $k > 0$ 时,则

$\forall u' \in N[(u,u') \in E] => \exists v' \in N[(v,v') \in E]$,使得 $u' \approx^{k-1} v', \lambda_E(u,u') = \lambda_E(v,v')$;

3) 当 $k > 0$ 时,则

$\forall v' \in N[(v,v') \in E] => \exists u' \in N[(u,u') \in E]$,使得 $v' \approx^{k-1} u', \lambda_E(v,v') = \lambda_E(u,u')$.

本文提出的的算法不是为了判断两个图是否是 k - 互模,而是将图中的点划分为不同的集合,同一集合内的点之间 k - 互模.

1.2 k-互模划分标识

定义 1.2 k 是一个非负整数,$G = < N, E, \lambda_N, \lambda_E >$ 是一个图,k - 互模划分标识是 $k+1$ 个函数映射的集合 $P = \{pId_0, K, pId_k\}$;对于 $0 \leqslant i \leqslant k$, pId_i 是从点集 N 到点编号集合的一个映射,并且对于 $\forall u, v \in N, pId_i(u) = pId_i(v)$ 当且仅当 $u \approx^i v$.

1.3 k-互模划分特征

将每个点划分到对应的集合中,基于每个点所在的位置为每个点建立"特征",特征的严格定义如下

定义 1.3 k 是一个非负整数,$G = < N, E, \lambda_N, \lambda_E >$ 是一个图,$P = \{pId_0, K, pId_k\}$ 是图 G 的 k - 互模划分标识,那么 $u \in N$ 的 k - 互模划分特征 $sig_k(u) = (pId_0(u), L)$. L 为点的位置信息,

$$L = \begin{cases} \varnothing, & \text{if } k = 0; \\ \{(\lambda_E(u,u'), pId_{k-1}(u')) \mid (u,u') \in E\}, & \text{if } k > 0. \end{cases}$$

1.4 局部互模划分样例

互模划分样例图见图 1,图 1(a)用来演示 1-局部互模划分的操作过程,图 1(b)是操作的结果.

首先计算点的 1-互模划分特征,点 1 的初始特征编号为 A. 由定义 1.3 可知,点 1 的 1-互模划分特征为(A,((a, B)(a, B))),点 2 和点 3 的 1-互模划分特征均为(B,((b, C))),点 4、5 和 7 的 1-互模划分特征均为(C,((c, D))),点 6 点的 1-互模划分特征为 (D,()).

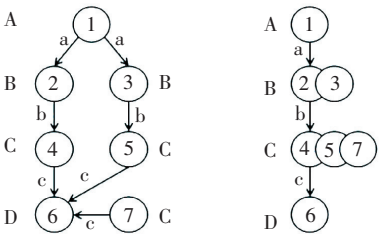

(a)k-互模划分操作过程 (b)k-互模划分的结果图(k=1)

图 1 K-互模划分样例

Fig.1 Example graph for K-bisimulation

1.5 GPS 分布式图数据处理平台

GPS 分布式图数据处理平台专门用于处理大图上的计算任务,其系统架构包含一个 Matser 节点(称为主节点)以及多个 Worker 节点(称为工作节点),工作节点使用 HDFS 分布式文件系统进行数据的存储,各节点之间的通信使用 Apache MINA[12]. GPS 分布式图数据处理平台的系统架构图,见图 2[10].

图数据的存储使用 HDFS 分布式文件系统,点被随机划分到各个工作节点中.

任务的计算分为多次迭代. 图中每个点有休眠态和激活态两种状态. 每个点的初始状态为激活态. 每一轮迭代开始,处于激活态的点向其出边邻居传输数据. 数据传输完成后,所有接收到数据的点都

被系统设置为激活态，点根据从其入边邻居传来的数据进行计算，并根据计算结果更新自己的信息. 在一轮迭代中，如果某个点并没有从其入边邻居中接受到数据，则自动在下轮迭代开始前进入休眠态. 当图中所有的点都处于休眠态的时候，程序结束.

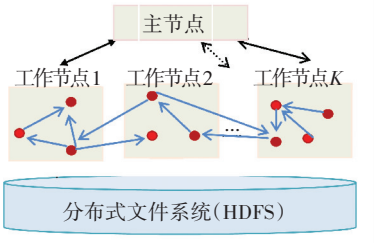

图 2　GPS 系统架构

Fig.2　GPS architecture

数据传输只在有边直接相连的点之间进行，从有向边的起点传输数据到有向边的终点. 当点和某一出边相邻点处在同一个工作节点(Worker)中的时候，它们之间的数据传输是不需要经过网络；当点和出边相邻点处在不同的工作节点上时，它们之间的数据传输通过网络完成. 为降低网络数据传输量，可以考虑减少处于不同工作节点上的点之间的边数，使文中图预划分处理可以取得良好效果.

基于 GPS 平台编程，就本文的互模划分算法而言，图中每个点的计算任务在 Vertex.compute( ) 函数中完成.

2　基于 GPS 的局部互模划分算法

为了高效并行进行图 k-互模划分计算，进行图的预划分操作，较大幅度地减少位于不同工作节点上的点之间的边数，这将较大幅度地减少通过网络传输的数据量；

“自动”实现点特征编号的更新，而不用为此增加额外操作；Luo 为了实现节点特征编号的更新，增加一次 MapReduce 操作. Schätzle 为实现节点特征编号的更新，不惜额外将图中每条边通过 MapReduce 处理，增加网络数据传输负担. 本文算法采用分布式图数据处理平台及相应的算法框架，无需为此增加额外操作.

采用哈希函数来计算节点特征的编号，这相比较于 Luo 的算法节省了很多运算；

为计算图中每个点的 k-互模划分特征，算法只需要利用到点的邻居(与点距离不超过 k)信息，采用 GPS 分布式图数据处理平台，可以充分利用到这种空间局域性.

2.1　算法描述

定义输入到 GPS 分布式图数据处理平台的图数据格式

<vertex-id><opt-vertex-value><outgoing-edge-id-1><opt-outgoing-edge-id-1-value><outgoing-edge-id-2><opt-outgoing-edge-id-2-value> …

每一行数据代表了图中一个点的信息，其中 vertex-id 表示点编号，opt-vertex-value 表示点的内容，outgoing-edge-id-1 表示该点的第一条出边指向的点的编号，opt-outgoing-edge-id-1-value 表示该点第一条出边的边值(在接下来的实验中，边值为该边的编号).

GPS 是要求输入按照点的标号从 0 开始输入，如果某个点没有边，那么也应独自占一行输入.

互模划分算法的部分(伪)代码实现

```
Pre_Process(G)
1void compute (inMessages , superstepNum)
2if (superstepNum == 0)
3     HashId = Hash(this.getVertexValue( ))
4     this.setID (HashId)
5     for (outEdge : this.getOutEdges( ))
6        edgeValue = outEdge. getEdgeValue( )
7        sendMessage (outEdge. getNeighborId( )
                      , (edgeValue, this.getID( ))
8     return
9if (superstepNum  < = k)

10     m_string = this.getVertexValue( )
11     for (mValue : inMessages)
12        m_string += mValue. toString( )
13     HashId = Hash(m_string)
14     this.setID (HashId)
15     for (outEdge : this.getOutEdges( ))
16        edgeValue = outEdge. getEdgeValue( )
17        sendMessage (outEdge. getNeighborId( )
                      , (edgeValue, this.getID( )) )
18     return
19voteToHalt( )
```

互模划分算法中，Pre_Process(G)代表算法的第一部分，进行图的预处理. 在整个算法的执行过程中，图的预处理只需要执行一次. 图的预处理需要完成以下 4 部分的工作：

1)将原始图数据转换成 GPS 要求的输入格式.

2)实现图中有向边方向的倒转，因为计算点的特征需要从其外向相邻点中获取信息，而 Pregel/GPS 中信息的发送是沿着有向边指向的方向，由有向边的起点向终点传递.

3)使用 METIS(由 Karypis Lab 开发的图切分软

件包)程序对图做预划分处理,为将划分后的多个子图输入到 GPS 中,需要对图数据进行转换.

4)平衡各个工作节点的工作量; 为均衡负载,实验在做预划分的时候将图划分后获得的子图数目是实验中使用的工作节点数目的 5 倍,即每个工作节点处理 5 个子图. 算法运行样例中预处理划分的子图数目等于工作节点数目.

函数 compute( )代表算法的第二部分代码. 在第 *superstepNum* 轮迭代中, 每个点均会执行一次 compute 函数, 执行完毕后 *superstepNum* 自动加一具体算法说明:

1)3~4 行代码根据点的内容计算点的初始特征编号,即 0-互模划分特征编号(k=0);

2)5~8 行代码向所有外出边相邻点发送点的初始特征编号以及边的编号,即发送($\lambda_E(u,u')$, $pId_0(u')$);

3)10~12 行代码从相邻点中获取自身的特征信息;

4)13~14 行代码计算点的特征编号,采用哈希函数来处理获取到的特征信息集合,进而获取特征编号;需要注意的是哈希值应当与特征信息集中元素的顺序无关;

5)15~18 行代码向所有外出边相邻点发送点的特征编号以及边的编号,即发送($\lambda_E(u,u')$, $pId_0(u')$);

6)当计算完 k-互模划分后,在第 19 行代码中点将自己的运行状态设置为休眠态. 程序中所有点在下一轮迭代开始前进入休眠态,程序结束.

2.2 算法运行样例

算法样例见图 3[7],为原始样例图的翻转图,即将原始样例图中的每条有向边边的指向颠倒.

点的初始内容(图中的 A,B)可根据需要选择是否输入到 GPS 中;出于完整性的考虑,互模划分算法的伪代码中以及本节的算法运行样例中均默认点的初始内容是存在的. 点的初始内容经过哈希函数的计算即可获得点的初始特征编号,即 0-互模划分特征编号.

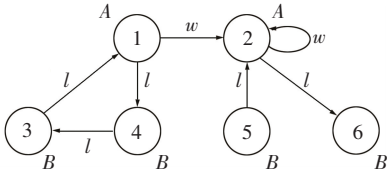

图 3 算法运行样例

Fig.3 The example graph for our algorithm

图 4 是图 3 输入到 GPS 平台的数据,每一行代表一个点的信息,第一列表示点标号,其中点 0 是 GPS 平台要求的输入,图 3 中并没有标识出这个点. 以"1A2w4l"为例,输入表示点的编号是 1,点的内容是 A,点的第一条出边指向点 2,该出边的内容为 w,点的第二条出边指向点 4,该出边的内容为 l. 根据 GPS 平台的默认处理(假设有两个工作节点),点 0、2、4、6 会被放在第一个工作节点中,点 1、3、5 会放在第二个工作节点中. 有 4 条边的起点和终点处于不同的工作节点中.

```
0
1  A  2  w  4  1
2  A  2  w  6  1
3  B  1  1
4  B  3  1
5  B  2  1
6  B
```

图 4 算法运行样例输入

Fig.4 The input to our algorithm

经过图的预划分处理,图从边(1,w,2)处分为两块子图. 第一个工作节点处理点 1、3、4,而第二个工作节点处理点 2、5、6、0,此时只有 1 条边的起点和终点处于不同的工作节点中. 为了将经过预划分的子图输入到 GPS 分布式图数据处理平台中,需要按照划分结果处理图 4 的算法运行样例输入,以便在 GPS 中实际的将点 1、3、4 放置于同一个工作节点中,将点 0、2、5、6 放置于另一个工作节点中. 处理的方法是将图 4 中的编号 0、1、2、3、4、5、6 分别映射成 0、1、2、3、5、4、6,再按照第一列排序. 这样做的依据是 GPS 平台内部默认的分配算法是将编号为 node_id 的点分配到编号为 vertex_id = node_id % vertex_num 的工作节点上,其中 vertex_num 为工作节点的数目.

第 0 轮迭代,图中各点根据点的内容计算初始特征编号,并沿着有向边向相邻点发送信息{边值,初始特征编号};

从第 1 轮到第 k 轮迭代,首先从相邻点获取其特征以及对应边的边值,加上点的内容, 即上文提到的$sig_i(u)=(pId_0(u),L)$,然后利用哈希函数计算点的当前特征编号,并更新;

当 k - 互模划分计算完成后,所有的点进入休眠态,程序结束.

2.3 算法的网络通讯量分析对比

前面提到的 3 种算法的本质是一样的,故而认为对于同一个计算任务三种算法所需要的迭代次数也是相同的,同时算法均需要有个终止条件判断部分,这部分需要的通讯量非常少,故而没有考虑这部分;对于 Hadoop 平台而言,无论 Mapper 和 Reducer 是否运行于同一台机器,两者之间的数据传输均使用网络,即可认为 Mapper 和 Reducer 之间所有的数

据均通过网络传输.

通过网络传输的数据主要有特殊标志、出发点编号、有向边的编号、终止点编号以及出发点所在的划分集合编号. 假定这 5 个元素的长度都是 a 个字节、图中点的个数为 N、边的个数为 M.

对于 Luo 的算法,第一次 MapReduce 操作通过网络传输的数据有两部分点编号,特别标注,点的初始集合编号,点在上一轮迭代后所在的集合编号以及发出点编号,有向边的编号,终止点编号,终止点在上一轮迭代后所在的集合编号. 合并起来,第一轮通过网络传输的数据规模为 $4 \times a \times N + 4 \times a \times M$; 第二次通过网络传输的数据为点编号,特殊标志,点的初始集合编号,点的特征,其中点的特征包括点上一轮迭代后所在的集合编号、从它出发的边编号以及指向的点的上一轮迭代后所在集合编号. 合并起来,第二次 MapReduce 操作通过网络传输的数据规模为 $4 \times a \times N + 2 \times a \times M$; 第三次 MapReduce 操作通过网络传输的数据为点编号,特殊标志,点所在的初始集合编号,点的本轮迭代后所在集合编号, 故而为 $4 \times a \times N$. 综合整个过程,每一轮迭代需要通过网络传输的数据总量为 $6 \times a \times M + 8 \times a \times N$.

对于 Schätzle 的算法,其需要通过网络传输的数据也有两部分:起始点编号,数字 0,起始点编号,边编号,终止点编号,终止点所在的集合编号和终止点编号,数字 1,起始点编号,边编号,终止点编号,终止点所在的集合编号, 为方便起见可认为数字 0 和数字 1 的大小也是 a 个字节. 可计算出来,通过网络传输的数据规模为 $6 \times a \times M + 6 \times a \times M = 12 \times a \times M$.

对于本文提出的算法,仅当边的起点和终点位于不同工作节点的时候,它们之间的数据传输才需要通过网络,假设这样的边的数目为 M'. 需要通过网络传输的数据为边编号,点在上一轮迭代后所在集合编号,终止点编号则总的网络数据传输规模为 $3 \times a \times M'$.

Luo 的算法的网络通讯量为 $6 \times a \times M + 8 \times a \times N$, 图中边的数目一般比点的数目要多许多, 如 Twitter[13] 的数据中边的数目几乎为点的数目的 30 倍. 故而可认为 Luo 算法的网络通讯量为 $6 \times a \times M$. Schätzle 的算法的网络数据通讯量为 $12 \times a \times M$.

实验数据, M' 在多数情况下相当于 M 的 1/3, 有些情况下甚至仅为 M 的 1/50. 这里取 $M' = M/3$, 所以本文提出的算法网络数据通讯量近似为 $a \times M$. 算法的网络数据通讯量下降为 Luo 的算法的 1/6, Schätzle 的算法的 1/12. 最坏情况下 $M' = M$, 算法的网络数据通讯量下降为 Luo 的算法的 1/2, Schätzle 的算法的 1/4.

通过分析,本文提出的算法的网络数据通讯量下降为 Luo 的算法的 1/2 ~ 1/6, Schätzle 的算法的 1/4 ~ 1/12.

3　数据转换算法

GPS 图数据处理平台对于图的输入格式有着较为严格的要求. 本文以 SP2Bench 图数据为例,介绍如何一般性的将格式迥异的大图数据转化为 GPS 要求的格式. 对于小图而言,由原始图数据生成 GPS 需要的数据相对简单,而对于本文实验采用的大图图包含几亿边、点而言则必须设计专门的分布式程序来处理. SP2Bench 的数据,每行对应一个三元组(点,边,点). 三元组的每一项都是字符串. 而 GPS 的输入要求边、点的编号均为整数且按照图的邻接表格式组织.

实验采用 Hadoop 平台来处理 SP2Bench 生成 GPS 的输入图. 程序分为三次 MapReduce 操作.

3.1　第一次 MapReduce 操作

第一次 MapReduce 操作的目的是获取 SP2Bench 生成的 RDF 三元组中每个元素的编号,算法伪代码见下面算法 GenID:

```
Map 操作:
GenIDMapper (key, value)
    v[ ] = value. split (" ")
    output (v[0], value +"," +"0")
    output (v[1], value +"," +"1")
    output (v[2], value +"," +"2")
Reduce 操作:
GenIDReducer (key, values)
  for (value : values)
     output (startNum + count ++, value)
  endfor
```

GenIDMapper 的执行分为以下 3 步:

1) 读取输入:按照 Hadoop 中默认的 TextInputFormat 方式从输入文件(SP2Bench 生成的图)中读取数据;读取到的 *key* 是一个 LongWritable 型的数值,表示当前读取的 *value* 数据相对于文件头的偏移量, *value* 是一行数据;

2) 中间处理:SP2Bench 生成的数据每一行都是一个按照空格隔开的三元组,所以读取数据后按照空格划分 *value*,获得 $v[i]$ 数组,该数组长度为 3;

3) 输出结果:一共有三组键值对输出, 第 i 组键值对的键为 $v[i]$,值为 *value* +"," +"i".

GenIDReducer 中有两个变量需要设置, 变量 *startNum* 和 *count* 均为 Reducer 的变量,只在每个

Reducer 启动时初始化,每次执行 GenIDReducer 函数的时候并不会对它们再次初始化. 使用 $count_i$ 来表示第 i 个 Reducer 中的变量 *count*,使用 $startNum_i$ 来表示第 i 个 Reducer 中的变量 *startNum*. $count_i$ 等于第 i 个 Reducer 中处理 *key* 的数目,初始化为 0. $startNum_i$ 等于前面 $i-1$ 个 *reducer* 所处理的 *key* 数目 $count_j$ 之和,$0 <= j <= i-1$. 由于程序运行前就需要设定 $startNum_i$ 的值,所以可以先执行一遍算法,然后利用实验结果去设定 $startNum_i$ 的值,之后再执行算法,得到最终的结果. 计算 $startNum_i$ 的公式如下所示:

$$startNum_i = \sum_{j=1}^{j<=i-1} count_j$$

GenIDReducer 的执行分为以下 3 步:

1)读取输入:获得 GenIDMapper 输出的键值对中的键以及该键对应的所有值的集合 *values*;Hadoop 将所有 GenIDMapper 输出的键值对中同一个键对应的值合并为值集合,且同一个键只会被一个 Reducer 处理.

2)中间处理:对于中的每个值 *value*,计算它的编号. 编号等于 *startNum* + *count* ++;

3)输出结果:对于 *values* 中的每个值 *value* 输出一个键值对,键为它的编号,值为 *value* 本身.

3.2 第二次 MapReduce 操作

第二次 MapReduce 操作的目的将 RDF 三元组的每个元素用编号替换,实现伪代码见算法 GenTriple:

```
Map 操作:
GenTripleMapper (key, value)
        v[ ] = value.split (",")
        output (v[0], key +"," + value)
Reduce 操作:
GenTripleReducer (key, values)
        for (value : values)
          v[ ] = value.split(",")
          t[v[1]] = v[0]
          output(null, t[0] +" " +t[1] +" " +t[2])
        endfor
```

GenTripleMapper 的执行分为 3 步:

1)读取输入:按照 Hadoop 中 KeyValueTextInputFormat 格式输入,读取到的 *key* 为 GenIDReducer 输出的键,读取到的 *value* 为 GenIDReducer 输出的值;

2)中间计算:将 *value* 按照逗号分成两部分,第一部分代表 SP2Bench 生成的 RDF 三元组,第二部分是一个数字,代表 *key* 在这个三元组中的位置.

3)输出结果:输出键值对的键为 SP2Bench 生成的 RDF 三元组,值为 *key*(RDF 三元组中元素的编号)以及该 *key* 代表的元素在三元组中的位置.

GenTripleReducer 的执行分为 3 步:

1)读取输入:由于同一个键的值会被同一个 Reducer 处理,所以获取的输入 *key* 为 SP2Bench 生成的 RDF 三元组,*values* 集合包括该三元组三个元素的编号以及元素在三元组中的位置;

2)中间计算:合并 *values* 中的三个 *value*,获得 RDF 三元组 3 个元素的编号;

3)输出结果:输出的键为空,值为结果编号后的 RDF 三元组.

3.3 第三次 MapReduce 操作

第三次 MapReduce 操作的目的是将编号后的三元组(边)转变为 GPS 输入文件,实现伪代码

```
Map 操作
MergeMapper (key, value)
  v[ ] = value. split (" ")
  output (v[2], v[0] +"," + v[1])
  output (v[0], "")
分区操作:
MergePartitioner (key, value, numPartition)
   return key > > k
Reduce 操作:
MergeReducer (key, values)
     result = key
       for (value : values)
          result += " " + value
          output(null, result)
     endfor
```

MergeMapper 的执行分为 3 步:

1)读取输入:按照 Hadoop 中默认的 TextInputFormat 方式读取,获取的 value 为编号后的三元组(边);

2)中间处理:从三元组中读取 3 个元素;

3)输出结果:输出两个键值对,第一个键值对键为三元组中的第三个元素,第一个键值对的值为三元组的第一个、第二个元素;第二个键值对的键为三元组的第一个元素,值为空,确保没有入边的点也存在于最终的输出中. 这样处理使得每条边的指向发生改变.

MergeReducer 的执行分为 3 步:

1)读取输入:获取的 *key* 为点(三元组中的元素)编号,*values* 集合中每个 *value* 代表为该点的一条出边;

2)中间处理:将同一个点的所有出边合并;

3)输出结果:键值对的键为空,值为点以及其所有出边.

Hadoop 通过 Partitioner 来将 Mapper 输出的数据分配到不同的 Reducer 上处理.

MergePartitioner 的作用是便于输出结果的合并. 由于 Hadoop 中 Reducer 处理的时候是按照键的先后顺序来一次处理的,所有 Reducer 输出的文件是有序的. 修改 Partitioner 使得不同 Reducer 处理的 key 是有序的,这样使得不同 Reducer 输出结果之间也是有序的.

MergePartitioner 执行的时候键值对 $(key, value)$ 被分配到第$(key >> k)$ 个 Reducer 中去. 计算变量 k 值的公式所示:

$$k = \left\lceil \log_2 \left(\frac{maxKey}{reducerNum} \right) \right\rceil. \qquad (1)$$

式中的变量 $maxkey$ 为图中最大的点编号,$reducerNum$ 为 Reducer 的数目.

图 5~7 分别表示了算法 GenID、算法 GenTriple 以及算法 Merge 的运行过程.

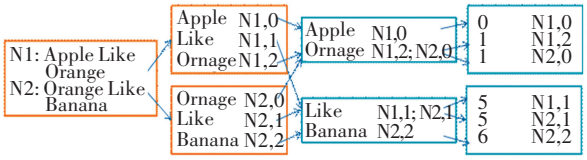

图 5　算法 GenID 运行过程示例

Fig.5　Computation process for algorithm GenID

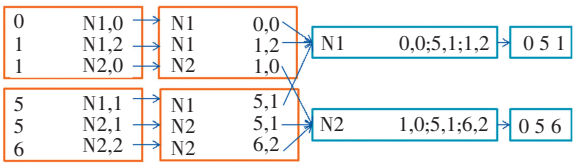

图 6　算法 GenTriple 运行过程示例

Fig.6　Computation process for algorithm GenTriple

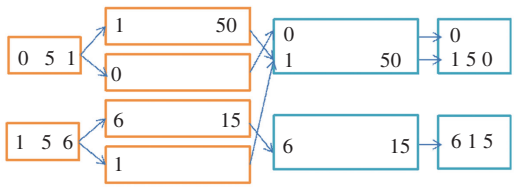

图 7　算法 Merge 运行过程示例

Fig.7　Computation process for algorithm Merge

每个算法是一次 MapReduce 操作,分为 4 个阶段:从文件读取输入;执行 Mapper 操作并输出 Mapper 结果;Reducer 获取输入、执行并输出;获取最终输出,存入文件. 图 5~7 中从左到右的四列图分别对应上述 4 个阶段.

图 5 中的 N1,N2 分别指代输入的第 1 行 RDF 三元组和第 2 行三元组,仅仅处于方便表示的目的. 实验中第一列并没有存储字符串 N1、N2,而第二列(以及图 6)中的 N1、N2 分别为字符串“Apple like Orange”以及“Orange like Banana”. 至此,完成了从 RDF 数据中生成 GPS 所需的输入图数据的过程.

对于 Twitter 图数据而言,数据本身已经是经过编号后的图数据,每行的两个整数分别代表着一条边的起点编号和终点编号. 可将上述算法稍加修改即可获得需要的 GPS 输入图数据.

数据流过程概括见图 8.

4　实验结果及性能分析

第一部分实验完整地执行了互模划分算法,而第二部分的实验并没有执行互模划分算法的 Pre_Process(G) 的图划分的操作. 这是因为实验预处理部分需要使用 METIS 程序对图进行划分,但是实验缺乏大内存机器,难以在大图上使用 METIS 程序进行划分操作.

图 8　转换三元组图数据输入到 GPS

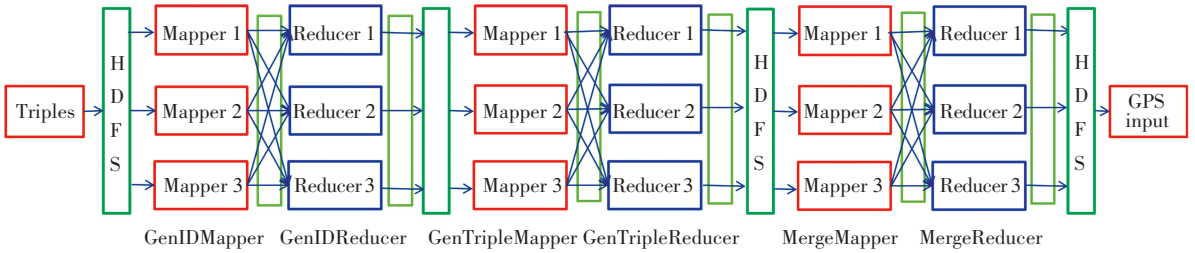

Fig.8　Whole computation process for converting initial graph to input into GPS

4.1　小图实验

4.1.1　实验环境

实验使用了 21 台机器(一个主节点,20 个工作节点)的机群. 其中,每台机器具备 8 核 Intel(R) Xeon(R) CPU,内存 8G. 实验存储使用 HDFS,版本为 Apache Hadoop 0.21.0; 编程使用 Java 1.6;GPS 使用的版本为 GPS 1.0;METIS 的版本为 METIS-5.1.0;

实验采用的数据有真实世界的数据(包含普通图数据[14]以及 RDF 数据[15]),也有生成的 RDF 数据 SP2Bench[16]表 1~8 中缩写为 SP_2-为系列数据集,此外为公共数据集. 表 1 是实验采用的图数据(非 RDF),表 2 是实验采用的 RDF 数据.

实验采用的数据规模相对较小,这是由于预划分处理使用的 METIS 是内存程序,而实验使用的机

器内存空间不够,难以处理更大级别的数据.

表 1 小图实验采用的图数据(非 RDF)

Tab.1 Non-RDF dataset for the small-graph experiments

图数据名称	点数	边数
soc-Epinions1	75 879	508 837
email-EuAll	265 214	420 045
com-DBLP	317 080	1 049 866
roadNet-PA	1 088 092	3 083 796
com-Youtube	1 134 890	2 987 624
roadNet-TX	1 379 917	3 843 320
roadNet-CA	1 965 206	5 533 214
wiki-Talk	2 394 385	5 021 410

表 2 小图实验采用的图数据(RDF)

Tab.2 RDF dataset for the small-graph experiments

图数据名称	三元组数/条边
Jamendo[17]	1 050 000
SP2_5	50 000
SP2_50	500 000
SP2_100	1 000 000
SP2_150	1 500 000
SP2_200	2 000 000
SP2_250	2 500 000

4.1.2 局部互模划分实验

实验中预划分处理使用 METIS 中的 METIS_PartGraphKwang( )函数来对图进行预划分,该函数可将图划分为大小均匀的 n 个子图. 同时为获得更为均匀负载,将图预划分为 100 个子图,每个工作节点处理 5 个子图数据.

在 GPS 中,图中各个点是依据点编号 node_id,将其放在编号为 node_id % num_vertex 的工作节点上面处理,其中 num_vertex 代表工作节点的数目. 这是一种随机均匀划分,未经划分处理的图数据实验作为对照组实验. 实验组采用划分后的图数据.

实验数据见表 3,其中 Edge_M 表示经过 METIS 划分之后分配到不同 Vertex 点之间的边数;Edge_R 表示经过 Random 划分之后分配到不同 Vertex 点之间的边数;r = Edge_M/ Edge_R 表示经过 METIS 划分后,起点和终点处于不同工作节点上的边数目的减少幅度.

实验之所以统计不同工作节点之间的边数,是因为在 GPS 中,信息是沿着有向边传输的,而同一工作节点内部点之间信息传递不用通过网络,不同工作节点之间信息传递通过网络,前者速度远高于后者(不考虑特殊情况,如建立超高速网络). 减少不同工作节点之间边数可有效地减少通过网络传输的信息量,从而提升性能.

表 3 图划分实验结果

Tab.3 Experimental results for graph partition

图数据名称	Edge_M/条	Edge_R/条	r
soc-Epinions1	343 894	483 461	0.711 317
email-EuAll	210 470	398 168	0.528 596
com-DBLP	376 568	1 994 400	0.188 813
roadNet-PA	12 690	2 928 512	0.004 333
roadNet-TX	10 282	3 651 672	0.002 816
roadNet-CA	12 906	5 256 744	0.002 455
com-Youtube	2 232 974	5 676 872	0.393 346
wiki-Talk	4 043 906	8 852 730	0.456 798
SP2_50	146 505	474 888	0.308 504
SP2_100	292 073	949 907	0.307 475
SP2_150	435 958	1 425 538	0.305 820
SP2_200	582 651	1 899 787	0.306 693
SP2_250	714 534	2 375 244	0.300 826

表 4 k-互模划分实验结果

Tab.4 Experimental results for k-bisimulation

图数据名称	划分前/秒	划分后/秒
SP2_5	52.596	53.583
SP2_50	61.797	60.593
SP2_100	66.797	60.610
SP2_150	86.702	74.676
SP2_200	128.767	113.750
SP2_250	157.456	136.773
com-DBLP	60.649	60.615
com-Youtube	91.699	105.745
wiki-Talk	117.728	139.895

从表 3 中可很明显地看出来,使用 METIS 划分后,不同工作节点之间的边数明显减少. 大多数图能获得 3 倍左右的收益(边数为对照组的 0.33 倍),其中 roadNet-PA,roadNet-CA, roadNet-TX 三个图甚至能获得几百倍的收益. 对于生成的 SP2Bench 图数据而言,收益稳定在 3 倍左右.

为衡量划分对于算法速度的提升,实验对比了划分前后算法运行时间,表 4 是实验结果,由于预处理只需要处理一次,下述时间统计并没有包含预处理时间;其次,k = 20,也就是计算了图的 20-互模划分.

图 9 为真实数据预处理前后算法运行时间对比图,图 10 为 RDF 数据数据预处理前后算法运行时间对比图.

当数据集合相对较小的时候,预划分处理对于算法性能影响不大,随着数据规模的增大,预划分的作用就逐渐显现出来.

4.1.3 实验结果分析

由于实验使用的数据规模有限且实验使用的机器设备性能差距悬殊,故而无法与前两种方法[7-8]做详细的对比,但是可以就部分数据进行对比.

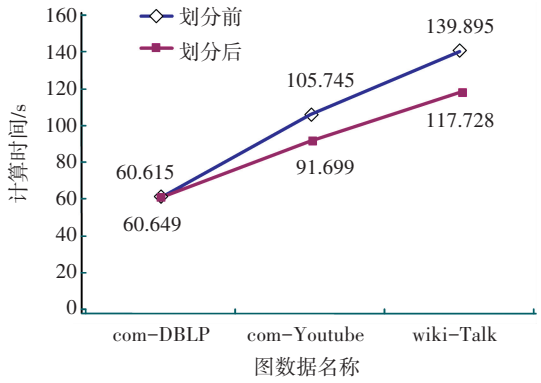

图 9　真实数据预处理前后运行时间对比

Fig.9　Run time comparisons for pre-partition on real dataset

对于使用 SP2Bench 生成的 1 000 000 个三元组的数据，Schätzle 的方法使用了 170 s 的时间. 他们使用的机器配置是这样的：Xeon E5-2420 1.9 GHz、6-core CPU, 32 GB RAM, 4 TB 磁盘空间. 而且他们只计算了图的 4-互模划分.

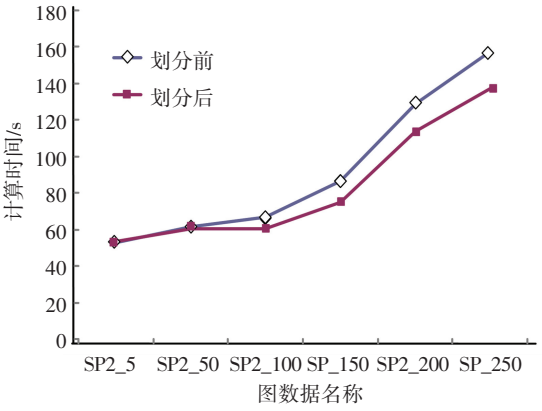

图 10　RDF 数据预处理前后运行时间对比

Fig.10　Run time comparisons for pre-partition on RDF dataset

相比较而言，本文实验使用的机器设备性能要差许多，而且计算的是图的 20-互模划分，即使如此，本文的方法仅需要 66 s，而进一步优化可使得所需时间下降到 60 s.

这个对比在一定程度上说明了本文的算法在时间效率上面的巨大优势.

4.2　大图实验

4.2.1　实验环境

实验采用的机群有 101 台机器（1 台机器作为主节点，100 台机器作为工作节点），每台机器具备 8 G内存和 1 T 硬盘. Hadoop（HDFS）版本为 1.2.1，GPS 版本为 GPS1.0. 表 5，表 6 为实验采用的数据.

4.2.2　图扩展性实验

图可扩展性实验，选取从 SP2Bench_100M（1 亿条边）到 SP2Bench_1000M（10 亿条边）十组图数据. 实验由于机器内存限制，对于 SP2Bench_100M 图数据使用 10 个计算节点（10 台机器），而对于 SP2Bench_200M 数据则使用 20 台计算节点，以此类推，对于 SP2Bench_1000M 数据则使用 100 个计算节点. 为了方便表示，将实验的计算时间 t 重新计算，计算公式为：

$$t' = \frac{t * NumofNode}{10}. \tag{2}$$

该计算公式默认计算节点增加的倍数同由此获得的计算时间加速的倍速相同. 而根据图 11 加速比的实验结果，实验节点增加 4 倍，实际获得的计算时间加速比为 3.5，这说明重新计算出的时间 t' 可以被用来近似 t.

表 5　大图实验采用的图数据（非 RDF）

Tab.5　Non-RDF dataset for the large-graph experiments

图数据名称	点数/个	边数/条
Twitter	41 652 230	1 468 365 182
RMAT[18]-100M	10 000 000	100 000 000
RMAT-500M	10 000 000	500 000 000
RMAT-1000M	10 000 000	1 000 000 000
RMAT-1500M	10 000 000	1 500 000 000
RMAT-2000M	10 000 000	2 000 000 000

表 6　大图实验采用的图数据（RDF）

Tab.6　RDF dataset for the large-graph experiments

图数据名称	三元组数/边数（单位：百万）
SP2Bench_10M	10
SP2Bench_100M	100
SP2Bench_200M	200
SP2Bench_300M	300
SP2Bench_400M	400
SP2Bench_500M	500
SP2Bench_600M	600
SP2Bench_700M	700
SP2Bench_800M	800
SP2Bench_900M	900
SP2Bench_1000M	100 0

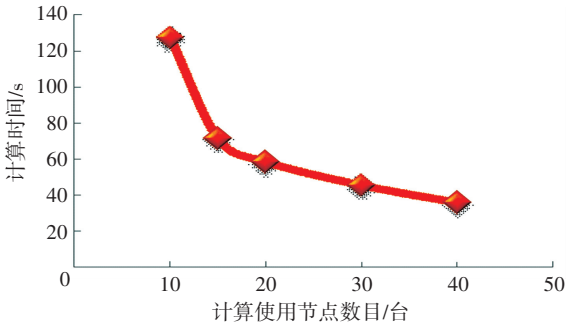

图 11　SP2Bench_100M 加速比实验

Fig.11　Experiment for speedup on SP2Bench_100M dataset

图 12 中的计算时间采用 t' 近似表示，实验结果显示算法计算大图上的 4 - 局部划分任务所需的时

间同图的规模呈线性关系. 算法显示出了良好的可扩展性.

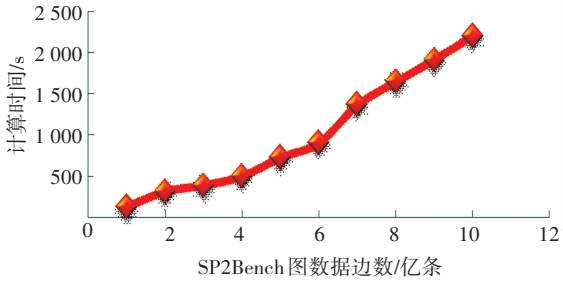

图 12 算法的可扩展性实验

Fig.12 Experimental results for scalability

4.2.3 算法高效性对比实验

实验难以与 Luo 以及 Schätzle 的实验算法做出相对准确的对比,这是由于 Luo 以及 Schätzle 实验使用的机群与本实验使用的机群在配置上差距甚殊. 表 7 是三组实验使用的机群配置.

表 7 实验机群配置对比

Tab.7 Comparison of cluster settings

机群名称	实验使用机器数目/台	单机器 CPU	单机器内存
Luo	72(6 Master node, 66Worker node)	2.0 GHz,8-Core	64 G
Schätzle	10	1.9 GHz,6-Core	32G
We	101(1 Master Node, 100 Worker node)	2.4 GHz,4-Core	8 G

三组实验机群的配置差别很大,在机器内存上的差距更是明显. 为便于比较三种算法的效率,实验分为两组,Twitter 图数据实验以及 SP2Bench 图数据实验. 两组实验分别用来同 Luo 以及 Schätzle 的实验算法进行效率比较.

Twitter 图数据实验使用 66 台机器作为工作节点(Worker node)以及 1 台机器作为主节点(Master node),计算 Twitter 图数据的 10-局部划分.

Luo 的算法包括基本的算法 Base Algorithm 以及两种改进版本算法,分别称之为 Fixed Signature Algorithm 以及 Merge Algorithm. 这三种算法在执行 10-局部划分实验的详细试验时间并没有给出,图 13 中的计算时间是根据其实验结果图近似估算的.

由图 13 可以直观地观察到,本文提出的 GPS-Based 算法明显快于 Luo 的算法. 与 Luo 三种算法中最快的 Fixed Signature Algorithm 相比,GPS-Based 算法的计算时间仅为其 1/7. 考虑到 Luo 实验使用的机群配置明显地优于本实验使用的机群配置,本文提出的 GPS-Based 算法的计算时间应当比 Luo 的算法快 7 倍以上.

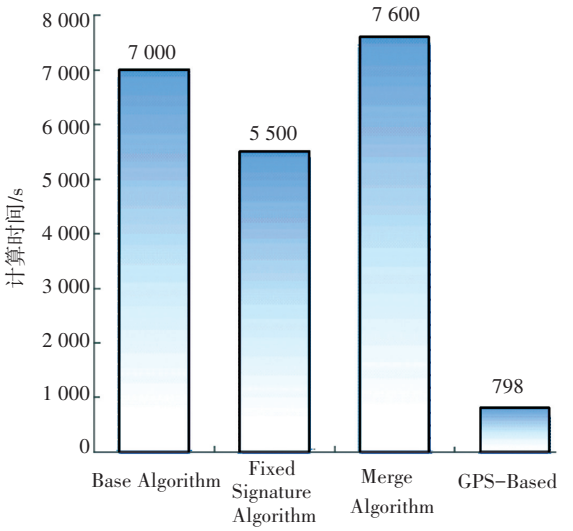

图 13 计算 Twitter 图数据 10-局部划分实验对比

Fig.13 Run time comparison for 10-bisimulation on Twitter dataset

SP2Bench 图数据实验分为 11 小组,由于机器内存的限制,对于部分数据采用多于 10 台机器来执行计算任务,表 8 详细地列出了各组实验使用的机器数目.

表 8 计算采用的机器数目和计算时间

Tab.8 Machine number and running time for computation

图数据名称	工作节点数目/台	计算时间/s
SP2Bench_10M	10	22.349
SP2Bench_100M	10	127.494
SP2Bench_200M	20	156.735
SP2Bench_300M	30	129.531
SP2Bench_400M	40	124.683
SP2Bench_500M	50	145.462
SP2Bench_600M	60	150.853
SP2Bench_700M	70	195.582
SP2Bench_800M	80	206.271
SP2Bench_900M	90	213.114
SP2Bench_1000M	100	221.058

为与 Schätzle 的实验结果作对比,需要将实际的计算时间转化为使用 10 台机器计算的时间. 加速比实验结果表明机器数目增加 4 倍可以获取 3.5 倍的时间加速,故而采用式(2)来近似估计只采用 10 台机器的计算时间.

图 14 表示在计算 SP2Bench 的 11 组图数据的 4-局部划分实验中,本文提出的 GPS-Based 算法同 Schätzle 的时间效率对比. 从图中可以很直观地看出,GPS-Based 算法的时间效率明显地优于 Schätzle 算法的时间效率.

综合上述 Twitter 图数据 10-局部划分实验以及 SP2Bench 图数据 4-局部划分实验的实验结果,本

文提出的 GPS-Based 算法明显地优于 Luo 以及 Schätzle 的实验算法. 图 15 表示三种算法的时间效率对比图，对于 Luo 的三种算法，本计算选用的是 Luo 结果优化后的 Fixed Signature Algorithm.

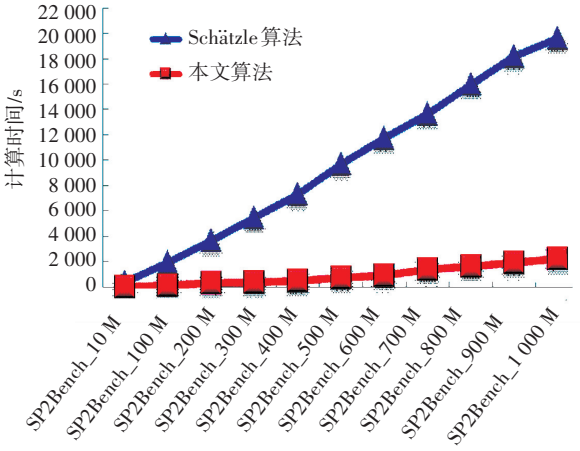

图 14　计算 SP2Bench 图数据 4-局部划分实验对比

Fig.14　Run time for 4-bisimulation on SP2Bench dataset

从图 15 可看出，本文提出的 GPS-Based 算法相较于 Luo 以及 Schätzle 的实验算法，在时间效率上有大幅度的提升，与 Schätzle 的算法相比有 10 倍的时间效率提升，与 Luo 的算法相比有 7 倍的时间效率提升. 如果考虑到实验机群配置对实验计算时间的影响，那么本文提出的 GPS-Based 算法在计算图的 k-局部划分任务上的时间效率优势还将进一步扩大.

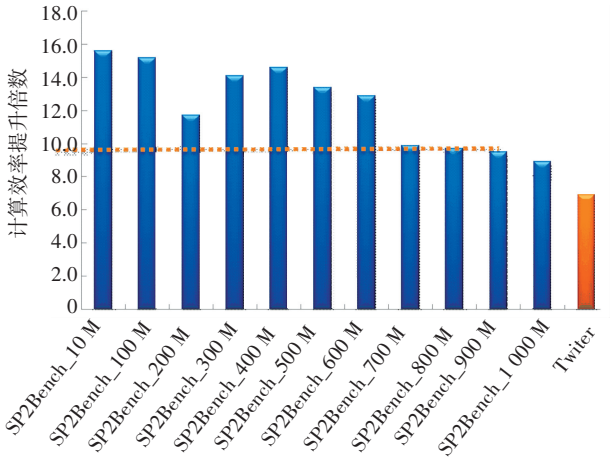

图 15　综合时间效率对比

Fig.15　Comparison on efficiency

4.2.4　图密度对算法性能的影响实验

本节实验衡量了图密度对于算法性能的影响，实验使用表 5 中的 RMAT[18] 图数据集. 实验使用 100 台工作节点，计算图的 4-局部划分. 图 16 是实验结果.

随着图密度的增加，算法执行所需的时间基本呈线性变化.

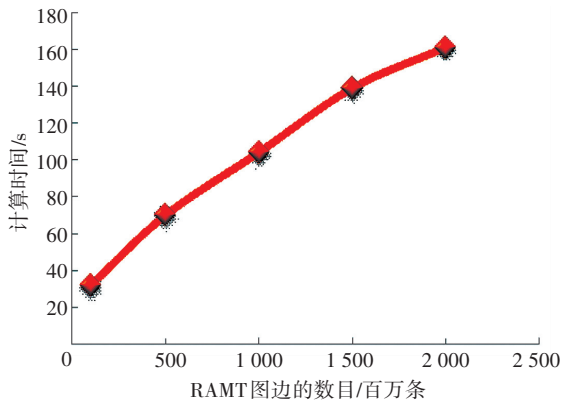

图 16　图密度对算法性能的影响

Fig.16　Experimental results on the impact of graph density

4.2.5　大图实验与小图实验的对比分析

在小图实验中，在 SP2_100（包含 100 万个 RDF 三元组）做 20-互模划分需要的实验时间是 66.8 秒，经过预划分处理，实验的时间是 60.6 s. 而在本节的实验中，在 SP2Bench_10（包含1 000万个 RDF 三元组）上的实验却只用了 22.3 s. 这是由于以下几个原因导致的：

1）小图实验中实验计算的是图上的 20-互模划分，而本节实验为便于同 Schätzle 的实验算法作比较，计算的是图上的 4-互模划分；

2）SP2_100 数据仅包含 100 万个 RDF 三元组，数据规模较小，未能完全使用 20 个工作节点的性能；根据表 4 的实验结果，SP2_50 图数据的规模为 SP2_5 图数据规模的 10 倍，而实际的运行时间却分别为 60.6 s 以及 53.6 s；

3）实验采用的机群不同，本节实验采用的机群配置虽然难以与 Schätzle 的实验机群以及 Luo 的实验机群相比较，但是与小图实验使用的机群相比性能还是高出不少；

4）本节实验针对之前的代码进行了较大幅度的优化，使用之前的代码计算 SP2Bench_10 数据上的 4-互模划分的时间是 33 秒，而优化后的计算时间是 22.3 s.

4.3　实验结果总结

通过上述实验，我们得到如下结论：

1）小图实验详细对比了各组数据在执行图的预划分处理（METIS 程序）前后的运行时间对比，充分地说明了图的预划分处理对于算法效率的影响.

2）图 11 所示的加速比实验，使用 10 台、15 台、20 台、30 台、40 台机器计算图数据 Sp2bench_100M 上的 4-互模划分. 计算节点增加了 4 倍获得了 3.5 倍时间加速，算法显示出了良好的加速比.

3）基于算法良好的加速比性能，实验将可扩展性各组实验的运行时间统一用式（2）进行计算，即

该实验在用十台机器来执行的时候所需的运行时间.

4)在图密度对于算法性能的影响实验中,使用表 5 中的 RMAT 图数据集,实验结果显示,随着图密度的增加,算法执行所需的时间基本呈线性变化.

5)表 7 给出了 Luo、Schätzle 以及本文大图实验所使用的实验环境对比,本文实验使用的机器性能最差,尤其以单机器内存上的差距最为悬殊.

6)图 13 给出了本文算法同 Luo 的算法(一个基本算法以及两个改进版本)在 Twitter 图数据 10-局部划分的实验对比. 本文算法的运行时间,是其三种算法中最快的算法的运行时间的 1/7,本文算法的高效性获得了很好的说明.

7)图 14 给出了本文算法同 Schätzle 的算法在 10 组大图数据上的执行 4-互模划分任务所需的计算时间对比,基本上本文算法运行时间仅为其 1/10 左右.

8)图 15 总结了本文算法相比较于 Luo 和 Schätzle 算法的时间效率对比,本文算法的高效性获得了充分的证明.

5 结 论

1)本文提出了目前第一个基于分布式图数据处理平台 GPS/Pregel 的 k-互模划分算法;

2)采用图的预处理操作,大幅减少子图之间的边数;

3)本文算法的网络通讯量仅为之前采用 MapReduce 计算模型算法的网络通讯量的 1/2 ~ 1/12;

4)在没有进行图的预处理操作的情况下,计算包含数亿条边的大图上的 k-互模划分任务,时间效率同之前的两种基于 MapReduce 计算模型的算法相比,提升了 7~16 倍;

第五,初步处理了不同工作节点之间的负载均衡问题.

参考文献

[1] SANGIORGI D, RUTTEN J. Advanced topics in bisimulation and coinduction [M]. New York, NY, USA: Cambridge University Press,2011:19-63.

[2] BUNEMAN P, GROHE M, KOCH C. Path queries on compressed XML [C]// Johann C, Lockemann P C, Abiteboul S, Carey. In Proc. VLDB 2003, Berlin, Germany: Morgan Kaufmann, 2003: 141-152.

[3] FAN W, LI J, WANG X, et al.Query preserving graph compression [C]// Chen Y, Richard S, Gravano L.In Proc. SIGMOD, Scottsdale, AZ, USA: ACM, 2012: 157-168.

[4] MILO T, DAN S. Index structures for path expressions [C]// Beeri C, Buneman P. In Proc. ICDT 1999. Germany : Springer, 1999: 277-295.

[5] PICALAUSA F, LUO Y, FLETCHER G H L, et al. A structural approach to indexing triples [C]// Simperl E, Cimiano P, Polleres A,et al. In ESWC, Heraklion. Greece: Springer, 2012:406-421.

[6] FAN W. Graph pattern matching revised for social network analysis [C]// Deutsch A. In Proc. ICDT, Berlin, Germany, USA: ACM, 2012: 8-21.

[7] LUO Y, LANGE Y D, FLETCHER G H L, et al. Bisimulation reduction of big graphs on mapReduce [M]. Berlin Heidelberg: Springer, 2013:189-203.

[8] SCHÄTZLE A, NEU A, LAUSEN G, et al. Large-scale bisimulation of RDF graphs [C]// Virgilio R D, Giunchiglia F, Tanca L. In Proc. SWIM. USA: ACM, 2013: 1-11.

[9] BLOM S, ORZAN S. A distributed algorithm for strong bisimulation reduction of state spaces [J]. STTT, 2005, 7(1): 74-86.DOI: 10.1007/s10009-004-0159-4

[10] SALIHOGLU S, WIDOM J. Gps: A graph processing system [C]//Balazinska M, Szalay A, Budavari T, et al. In Proc. SSDBM, Baltimore, Maryland. USA: ACM, 2013: 22-33.

[11] MALEWICZ G, AUSTERN M H, BIK A J C, et al.Pregel: a system for large-scale graph processing [C]// Agrawal D, Elmagarmid A. In Proc. SIGMOD. USA: ACM, 2010: 135-146.

[12] Apache. Apache MINA [EB/OL]. (2015). http://mina.apache.org/.

[13] KWAK H, LEE C, PARK H, et al. What is twitter, a social network or a news media? [C]// Rappa M, Jones P, Freire J. Proceedings of the 19th International Conference on World Wide Web. USA: ACM, 2010:591-600

[14] LESKOVEC J, KREVL A. Stanford large network dataset collection [DB/OL].http://snap.stanford.edu/data/index.html

[15] RIXHAM N, SPORNY M, BIRBECK M. RDF[EB/OL]. (2012.7).http://www.w3.org/standards/techs/rdf.

[16] BONCZ P, ERLING O. Social Network Intelligence BenchMark [EB/OL].(2013.7). https://www.w3.org/wiki/Social_Network_Intelligence_BenchMark

[17] Semantic Web Education, Outreach. jamendo. [DB/OL]. http://dbtune.org/jamendo/

[18] CHAKRABARTI D, ZHAN Y, FALOUTSOS C. R-MAT: A recursive model for graph mining [C]// Berry M W, Dayal U, Kamath C, et al. SDM 2004. USA: SIAM, 2004: 442-446.

(编辑 苗秀芝)