

混合云环境下面向代价优化的 workflow 数据布局方法

黄引豪^{1,2} 马 鄂³ 林 兵^{2,4} 於志勇^{1,2} 陈 星^{1,2}

(福州大学数学与计算机科学学院 福州 350116)¹

(福建省网络计算与智能信息处理重点实验室 福州 350116)²

(清华大学软件学院 北京 100084)³ (福建师范大学物理与能源学院 福州 350117)⁴

摘 要 科学 workflow 在混合云中执行会产生大量的跨数据中心传输,造成严重的传输时延及代价。为了对混合云环境下的科学 workflow 数据进行合理布局,兼顾公有云和私有云的优势,优化数据布局代价,提出了一种基于遗传粒子群优化混合算法(GAPSO)的数据布局策略。该方法考虑了公有云数据中心与私有云数据中心的不同特点(如存储容量、存储代价等因素以及数据传输时延约束)对传输代价的影响,并结合遗传算法与粒子群优化算法的优点,生成科学 workflow 的布局策略。实验结果表明,基于 GAPSO 的数据布局策略能够有效减少混合云中科学 workflow 运行时的数据布局代价。

关键词 混合云,数据布局,传输时延约束,代价优化

中图分类号 TP338 文献标识码 A

Cost-driven Workflow Data Placement Method in Hybrid Cloud Environment

HUANG Yin-hao^{1,2} MA Yun³ LIN Bing^{2,4} YU Zhi-yong^{1,2} CHEN Xing^{1,2}

(College of Mathematics and Computer Science, Fuzhou University, Fuzhou 350116, China)¹

(Fujian Provincial Key Laboratory of Network Computing and Intelligent Information Processing, Fuzhou 350116, China)²

(School of Software, Tsinghua University, Beijing 100084, China)³

(College of Physics and Energy, Fujian Normal University, Fuzhou 350117, China)⁴

Abstract Scientific workflow execution in hybrid cloud will generate a lot of transmission across data centers, resulting in large quantities propagation delay time and cost. In order to make a reasonable data placement of scientific workflow in hybrid cloud environment, it takes into account the advantages of public cloud and private cloud, and optimizes the cost of data placement. A data placement strategy based on genetic algorithm particle swarm optimization (GAPSO) was proposed, which considers the different characteristics between public cloud data centers and private cloud data centers such as capacity and storage cost as well as the influence of propagation delay time constraint on transmission costs and combining the advantages of genetic algorithm and particle swarm optimization algorithm, and data placement strategy for scientific workflows was generated. The experimental results show that the data placement strategy based on GAPSO can effectively reduce the cost of data placement of scientific workflow in hybrid cloud.

Keywords Hybrid cloud, Data placement, Propagation delay time constraint, Cost-driven

1 引言

科学 workflow 是一种以降低计算成本为目标的海量密集数据流的典型应用系统^[1]。科学 workflow 中计算任务节点之间的依赖关系非常复杂,数据集的大小可以达到 TB 甚至 PB 量级。随着云计算^[2]的出现,其高效、灵活、可伸缩性等特点为执行大型科学 workflow 提供了新的思路。云上充足的计算、存储与网络资源等^[3-4]使得科学 workflow 能更好地执行。通过在云环境下执行科学 workflow,可以有效减少执行代价,降低成本,然而如何在云上合理调度和管理资源是云计算目前面临

的一个重要问题^[5-6]。混合云是一种融合了公有云和私有云的混合计算环境^[7-8],公有云以其高伸缩性、低成本、可定制^[9]等特点为科学 workflow 的执行提供了服务保障,而私有云是一个公司或组织建立的内部数据存储中心。混合云结合了公有云与私有云各自的优势^[10],而混合云环境下的科学 workflow 研究已经成为了科学 workflow 研究的热点。在混合云环境下对科学 workflow 进行数据布局,需要综合考虑公有云与私有云的优势。如何针对公有云与私有云各自的优势,降低数据传输时延以及数据布局代价,形成合理的数据布局方案成为了科学 workflow 数据布局问题的新挑战。

本文受国家自然科学基金(61772136),福建省自然科学基金(面上项目)(2019J01061386),福建省教育厅中青年教师教育科研项目(JT180098)资助。

黄引豪(1996-),男,硕士生,主要研究方向为云计算;马 鄂(1989-),男,博士,主要研究方向为移动计算、服务计算;林 兵(1986-),男,博士,讲师,主要研究方向为云计算技术;於志勇(1982-),男,博士,副教授,主要研究方向为移动社会网络, E-mail: yuzhiyong@fzu.edu.cn (通信作者);陈 星(1985-),男,博士,副教授,主要研究方向为软件自适应。

现有数据处理工作中,大多采用聚类算法^[11]将数据进行划分,以达到各数据中心的负载均衡,但未充分考虑数据中心间产生的巨大数据传输。Yuan 等^[12]提出了一种基于矩阵数据划分的数据布局策略,将科学 workflow 中的数据通过聚类矩阵划分成 K 个集合,从而使集合内部的数据集高内聚而集合之间的数据集低耦合,通过该数据划分方法可以有效降低数据传输次数,但是其忽略了数据中心存储容量的限制。Deng 等^[13]在 Yuan 等^[12]提出的基于矩阵数据划分的数据布局策略的基础上,提出了一种高效的任务与数据集的协同调度策略,通过降低数据中心间的数据传输总量,优化科学 workflow 数据布局,但其没有考虑不同数据中心的存储容量差异。Wang 等^[14]基于 K-均值聚类策略,用一种数据复制机制来减少数据传输次数,提出了一种云环境下的科学 workflow 数据布局方案,但未考虑数据复制产生的代价。程慧敏等^[15]针对数据中心间的负载均衡,提出了一种基于多目标优化的数据布局策略。首先将固定数据集部署到相应的数据中心,然后利用多目标优化算法 KnEA 对剩余数据集进行布局,其算法具有良好的收敛性,并且综合考虑多个优化目标间的平衡,取得了传输时间和负载均衡都表现良好的数据布局方案,但未考虑云数据中心的存储代价及云数据中心间的传输代价,可能导致巨大的 workflow 执行代价。

王东亮等^[16]提出融合负载均衡和蝙蝠算法,利用负载均衡对蝙蝠种群数据进行初始化,提高初始样本数据解的质量,有较快的收敛速度和较高的寻优精度,但其忽略了任务间的依赖关系所造成的数据传输。Zhao 等^[17]通过不同数据集大小不同的特点,构造数据关联性矩阵来预估数据传输代价,设计出一种通过预测中间传输数据大小来降低数据传输量的科学 workflow 数据布局方案,从而优化数据传输量,但未对数据中心之间的带宽差异做充分考虑。Zhang 等^[18]引入了一种称为虚拟数据代理(VDA)的新型实体,提出了基于云模型的虚拟数据代理(CDPVDA)数据布局算法,将数据放置问题转换为两个映射过程,即从数据集到虚拟数据代理的映射和从虚拟数据代理到数据中心的映射,有效降低了数据中心之间的数据传输开销,但其未考虑 workflow 传输时延约束对数据布局的影响。

因此,针对混合云环境下面向代价驱动的工作流数据布局问题,目前研究工作尚未形成一个完整有效的解决方案。针对传统数据布局方法中存在的缺陷,受 Peng 等^[19]工作的启发,本文提出一种基于遗传粒子群优化混合算法(GAPSO)的数据布局策略,目的是优化科学 workflow 数据传输与存储代价。该方法通过考虑了公有云数据中心与私有云数据中心的不同特点,以及数据传输时延约束对数据传输与存储代价的影响,结合遗传算法与粒子群优化算法的优点,有效减少了数据传输与存储代价。

2 混合云环境下的科学 workflow 数据布局问题

定义 1(科学 workflow) 科学 workflow 由有向无环图 $W = (T, DS, E, G)$ 组成,其中 $T = \{t_1, t_2, \dots, t_n\}$ 表示包含 n 个任务的集合;而 $DS = \{ds_1, ds_2, \dots, ds_m\}$ 表示该科学 workflow 中所有数据集的集合; E 表示任务与数据之间的依赖矩阵,若 $e_{ij} = 1$,代表任务 t_j 的执行需要数据集 ds_i 。 G 表示数据与任务之间的依赖矩阵,若 $g_{mn} = 1$,代表数据集 ds_m 是由任务 t_n 产生。

定义 2(任务) 科学 workflow 中的每个任务 $t_i = \langle Input_i, Output_i \rangle$,其中 $Input_i$ 表示输入数据集的集合, $Output_i$ 表示输出数据集的集合。在科学 workflow 中,任务和数据集之间的关系是多对多的,一个任务可以产生多个数据集,一个数据也可以被多个任务使用。

定义 3(数据集) 科学 workflow 中的每个数据集 $ds_i = \langle size_i, gt_i, pc_i \rangle$,其中 $size_i$ 表示该数据集的大小, gt_i 表示生成数据集 ds_i 的任务, pc_i 表示 ds_i 必须存放的私有数据中心。其中 gt_i 由式(1)表示, pc_i 由式(2)表示:

$$gt_i = \begin{cases} 0, & ds_i \in DS_{mit} \\ GT(ds_i), & ds_i \in DS_{gen} \end{cases} \quad (1)$$

$$pc_i = \begin{cases} 0, & ds_i \in DS_{pub} \\ place(ds_i), & ds_i \in DS_{pri} \end{cases} \quad (2)$$

其中, DS_{mit} 和 DS_{gen} 分别表示初始数据集集合和生成数据集集合,初始数据集是科学 workflow 的原始输入,而生成数据集是科学 workflow 运行过程中产生的数据集, $GT(ds_i)$ 表示产生数据集 ds_i 的任务。数据集按照其隐私性又可以分成隐私数据集 DS_{pri} 和非隐私数据集 DS_{pub} , $place(ds_i)$ 表示 ds_i 指定存放的数据中心。

定义 4(数据中心) 混合云环境由多个数据中心组成,数据中心集合 $DC = \{dc_1, dc_2, \dots, dc_n\}$,其中 $dc_i = \langle size_i, availsz_i, pri_i, storecost_i \rangle$ 。 $size_i$ 表示数据中心 dc_i 的存储容量,数据集在数据中心 dc_i 上存放时,数据中心 dc_i 上的数据集总大小不能超过其存储容量。 $availsz_i$ 表示数据中心 dc_i 的可用容量。 pri_i 表示该数据中心的类型,当 $pri_i = 1$ 时,表示该数据中心属于私有云数据中心,能够存放隐私数据和非隐私数据;当 $pri_i = 0$ 时,表示该数据中心属于公有云数据中心,只能存放非隐私数据。 $storecost_i$ 表示存储单位容量的数据需要的花费。根据文献^[20],私有云的建立及维护等需要花费大量代价,因此私有云存储代价会远远大于公有云存储代价。

定义 5(带宽矩阵) 不同数据中心之间具有不同的传输带宽,其中对于 $\forall i, j = 1, 2, \dots, |DC|$ 且 $i \neq j$, $band_{ij}$ 表示数据中心 dc_i 和数据中心 dc_j 之间的网络传输带宽,并且 $band_{ij} = band_{ji}$ 。本文实验假设数据中心的带宽值是固定的,即不会产生变化。因为地理距离等原因,私有云数据中心间的带宽大小大约是公有云数据中心的带宽的 10 倍^[21]。

定义 6(传输代价矩阵) 不同数据中心之间具有不同的单位传输代价,对于 $\forall i, j = 1, 2, \dots, |DC|$ 且 $i \neq j$, $cost_{ij}$ 表示数据中心 dc_i 和数据中心 dc_j 之间的单位传输代价,并且 $cost_{ij} = cost_{ji}$ 。由于私有云之间使用内网传输,所以相比于私有云与公有云之间的数据传输,私有云之间的数据传输代价可以忽略不计。

定义 7(数据布局方案) 本文将整个数据布局的方案定义为 $S = (Map, Trans, C_{total}, T_{total})$,其中 Map 是数据放置的映射集合,集合中每一个元素 $map(ds_i, dc_j)$ 表示数据集 ds_i 被放置在数据中心 dc_j 上。 $Trans = \{trans_1, trans_2, \dots, trans_n\}$ 表示一组产生传输代价的数据调度集合, $trans_n = \langle ds_k, dc_i, dc_j \rangle$ 表示数据集 ds_k 从数据中心 dc_i 传输到数据中心 dc_j 的一次传输,该传输将同时产生传输时间和传输代价,其中传输时间如式(3)所示,传输代价如式(4)所示。

$$T_i(trans_i) = T_i \langle ds_k, dc_i, dc_j \rangle = \frac{size_k}{band_{ij}} \quad (3)$$

$$C_t(trans_i) = C_t \langle ds_k, dc_i, dc_j \rangle = \frac{size_k}{cost_{ij}} \quad (4)$$

数据的存储总代价 C_{store} 如式(5)所示:

$$C_s = \sum_{i=1}^{|DC|} (size_i - avails_i) \cdot storecost_i \quad (5)$$

C_{total} 表示该数据布局下, 整个科学工作流完成时产生的总代价, 如式(6)所示。 T_{total} 表示该数据布局下, 科学工作流的总传输时延, 如式(7)所示。

$$C_{total} = C_s + \sum_{i=1}^{|Trans|} C_t(trans_i) \quad (6)$$

$$T_{total} = \sum_{i=1}^{|Trans|} T_t(trans_i) \quad (7)$$

同时, 对于整个科学工作流, 我们定义一个总传输时延约束 $TimeLimit$, 表示该工作流产生的总传输时延不能超过该约束。

通过上述的基本定义, 本文中混合云环境下面向代价优化的科学工作流数据布局问题可用式(8)表示, 其主要目标是 minimized 数据布局总代价 C_{total} 的同时, 满足科学工作流的总传输时延约束和每个数据中心的容量限制。

$$\begin{aligned} & \text{Minimize } C_{total} \\ & \text{subject to } T_{total} \leq TimeLimit \\ & \text{subject to } \forall i, avails_i \geq 0 \end{aligned} \quad (8)$$

3 基于 GAPSO 的数据布局策略

3.1 粒子群优化算法 (PSO)

PSO 算法^[22]属于进化算法的一种, 通过模拟自然界鸟群迁徙的活动, 让粒子不断地迭代从而寻找最优解。粒子在 PSO 算法中是非常重要的概念, 每一个粒子代表优化问题的一个候选解, 粒子通过自身历史最优值与族群历史最优值不断在解空间中迭代更新。式(9)是粒子的速度公式, 式(10)是粒子的位置公式。

$$V_i^{t+1} = \omega \times V_i^t + c_1 r_1 (pBest_i^t - X_i^t) + c_2 r_2 (gBest^t - X_i^t) \quad (9)$$

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (10)$$

其中, t 代表当前的迭代次数, V_i^t 和 X_i^t 分别表示第 i 个粒子在第 t 次迭代时的速度和位置。 ω 为惯性权重, 表示粒子具有保持当前速度的能力。 $pBest_i^t$ 和 $gBest^t$ 分别表示在第 t 次迭代后的粒子自身历史最优值与种群历史最优值。 r_1 和 r_2 是两个随机因子。 c_1 和 c_2 是学习因子, 可以控制粒子对自身历史最优值与种群历史最优值的学习能力。另外, 为了评价粒子的优劣性, PSO 应用了一种适应度评价函数。

3.2 遗传算法 (GA)

GA 算法^[23]是通过模拟生物界中生物进化过程的计算模型。遗传算法同样从随机解出发, 按照自然界优胜劣汰的原则, 通过上一代优秀个体的组合交叉和变异过程, 逐代演化生成越来越好的下一代个体, 从而找到更优的近似解。

3.3 基于遗传粒子群优化混合算法 (GAPSO) 的数据布局策略

受 Peng 等^[19]工作的启发, 本文提出一种基于遗传粒子群优化混合算法 (GAPSO) 的数据布局策略, 旨在解决混合云下数据布局产生的大量跨数据中心传输代价及数据存储代价的问题。

GAPSO 算法通过引入 PSO 算法对粒子个体的优化过程, 使 GA 算法中的粒子个体得到优化, 从而解决了 GA 算法搜索后期效率低下的问题。GAPSO 算法先通过粒子的适应度评价函数对粒子进行排序, 保留其中优秀的个体用于下一

次 PSO 算法迭代, 而淘汰表现较差的个体。通过对优秀个体的交叉与变异操作得到剩下的粒子, 进入下一代。

3.3.1 问题编码

问题编码的方式会直接影响算法搜索效率和性能, 因此我们需要一种好的问题编码来解决科学工作流数据布局问题。本文采用数据集-数据中心的离散编码方式来构造粒子。在第 t 次迭代时, 粒子 i 的位置 X_i^t 如式(11)所示。

$$X_i^t = (x_{i1}^t, x_{i2}^t, \dots, x_{in}^t) \quad (11)$$

每个粒子由 n 维元素组成, n 代表科学工作流中非隐私数据集的数量。 x_{ik}^t ($k=1, 2, \dots, n$) 表示第 k 个非隐私数据集在第 t 次迭代的存储的数据中心编号, 即 x_{ik}^t 的取值范围为 $[1, |DC|]$ 。因为在混合云环境下, 隐私数据集的存储位置始终是固定不变的, 不会因粒子的迭代而变化, 所以本文只对非隐私数据集进行编码。

3.3.2 适应度函数

粒子适应度函数是评价粒子优劣性的主要指标, 通常规定适应度函数值较小的粒子对应更优的解。由于会出现粒子对应的解的总传输时延超过约束总传输时延或某个数据中心存储的数据集总大小超过其容量, 则该粒子为不可行粒子的情况, 因此需要对可行粒子与不可行粒子的适应度函数区分定义。本文的目的是最小化科学工作流数据布局的跨数据中心传输与存储代价, 所以可以直接将适应度函数定义为该粒子所对应解的数据布局总代价, 这样, 粒子适应度值越小的粒子表现越优。

定义 8(可行解粒子) 编码粒子所对应的数据布局总传输时延小于总传输时延限制要求, 且所有数据中心的剩余可用容量均大于 0。

定义 9(不可行解粒子) 编码粒子所对应的数据布局总传输时延大于科学工作流总传输时延限制要求, 或某个数据中心的剩余容量小于 0。

适应度函数如式(12)所示。

$$\text{fitness} = \begin{cases} \text{infinite}, & T_{total}(X_i) > TimeLimit \text{ 或} \\ & \exists i, avails_i < 0 \\ C_{total}, & \text{其他} \end{cases} \quad (12)$$

若粒子为可行解粒子, 则其适应度函数值为其数据布局总代价 C_{total} , 若粒子为不可行解粒子, 则将其数据布局总代价视为无限, 即其适应度函数值为无限大。

3.3.3 粒子更新策略

为结合 PSO 算法与 GA 算法各自的优点, 粒子采用如下更新策略。

(1) 初始化种群。

(2) 对于每一代粒子, 按照适应度函数值排序, 选择前 50% 的优秀个体, 通过式(13)进入到下一代。

$$X_i^t = c_2 \oplus G_x(c_1 \oplus P_x(X_i^{t-1}, pBest_i^{t-1}), gBest^{t-1}) \quad (13)$$

其中个体交叉部分与种群交叉部分如式(14)与式(15)所示:

$$\begin{aligned} B_i^t &= c_1 \oplus P_x(X_i^{t-1}, pBest_i^{t-1}) \\ &= \begin{cases} P_x(X_i^{t-1}, pBest_i^{t-1}), & c_1 > r_1 \\ X_i^{t-1}, & \text{其他} \end{cases} \end{aligned} \quad (14)$$

$$\begin{aligned} A_i^t &= c_2 \oplus G_x(B_i^{t-1}, gBest^{t-1}) \\ &= \begin{cases} G_x(B_i^{t-1}, gBest^{t-1}), & c_2 > r_2 \\ B_i^{t-1}, & \text{其他} \end{cases} \end{aligned} \quad (15)$$

r_1 与 r_2 是两个随机因子, 取值范围为 $[0, 1]$, G_x 与 P_x 分

别表示族群交叉操作与个体交叉操作。随机选择编码粒子的两个分位,将这两个分位之间的所有分位,替换成 $gBest$ 与 $pBest$ 中相同分位的数值。如图 1(a)是个人(社会)认知部分的交叉操作。随机选择编码粒子的两个分位(p_1, p_2),将原粒子(p_1, p_2)分位之间的值替换成 $pBest(gBest)$ 在相同分位的值,形成新粒子。





图 1 粒子更新操作

若变化后的粒子为不可行解粒子,则重新对原粒子进行变化直到其变为可行解粒子。

3)剩下的 50% 个体,随机选取前 50% 优秀个体中的一个,进行遗传算法中的交叉与变异操作,然后进入下一代,其变化如式(16)所示:

$$X_i^t = G_x(\omega \oplus M_x(X_i^{t-1}), gBest^{t-1}) \quad (16)$$

其中变异部分如式(17)所示:

$$C_i^{t-1} = \omega \oplus M_x(X_i^{t-1}) = \begin{cases} M_x(X_i^{t-1}), & \omega > r_3 \\ X_i^{t-1}, & \text{其他} \end{cases} \quad (17)$$

r_3 是随机因子,取值范围是 $[0, 1]$, M_x 表示遗传算法中的变异操作。随机选取编码粒子中的任何一个分位,在取值范围内随机改变该分位的值。图 1(b)给出了变异过程,随机选取编码粒子的一个分位 p_1 ,将该分位的值从 3 变成了 1。

若变化后的粒子为不可行解粒子,则重新选择前 50% 优秀个体中的一个进行交叉与变异操作,直到下一代种群个体数目达到原始种群规模。

3.3.4 粒子到解的映射

算法 1 粒子到解的映射

输入:科学工作流 G , 数据中心集合 DC , 粒子 X

输出:该粒子对应数据布局的总代价 C_{total}

1. 初始化相关参数
2. foreach ds_i in DS // 放置数据集
3. $dc_{avail}(X[i]) += ds_{size}_i$
4. $C_{total} += ds_{size}_i * storecost_{X[i]}$
5. if $dc_{avail}(X[i]) > capacity_{X[i]}$
6. return 该粒子是不可行解粒子
7. end if
8. end for
9. foreach t_j in T
10. 将任务 t_j 放置在传输代价最小的数据中心 dc_k
11. foreach ds_j in $IDS_j \cup ODS_j$
12. if ds_j 放在 dc_p 上且 $p \neq k$
13. put(ds_j, dc_k, dc_p) in $Trans$
14. end if

15. end for
16. end for
17. foreach $trans_i$ in $Trans$
18. $T_{total} += T_i(trans_i)$
19. $C_{total} += C_i(trans_i)$
20. end for
21. if $T_{total} > TimeLimit$
22. return 该粒子为不可行解粒子
23. end if
24. 输出 C_{total} 和相应的数据布局方案

4 实验结果与分析

4.1 实验环境

基于文献[24],将 GAPSO 算法的相关参数设置为:最大迭代次数 1000,初始种群规模 100, $\omega_{max} = 0.9, \omega_{min} = 0.4, c_1^{start} = 0.9, c_1^{end} = 0.2, c_2^{start} = 0.9, c_2^{end} = 0.4$ 。对于算法的惯性因子 ω 、自身认知因子 c_1 和种群认知因子 c_2 均采用线性增减策略进行设置。本文采用 Bharath 等[25]研究的来自 5 个不同科学领域的科学工作流作为实验的数据来源,每种工作流均包含多种不同规模的科学工作流,本文只选取其中两种进行实验:小型(约 30 个任务)、中型(约 50 个任务)。混合云环境包括 3 个数据中心 $\{dc_1, dc_2, dc_3\}$,其中 dc_1 是容量无限的公有云数据中心, dc_2 和 dc_3 是私有云数据中心。不同科学工作流的数据量大小均有差异,所以将每个私有云容量设为该工作流数据集总大小的 40%。每个工作流都有一个对应的总传输时延限制,我们选择 4 个不同的总传输时延限制 $TimeLimit(\omega)$ 来测试本文数据放置策略的性能。

$$TimeLimit(\omega) = r_i \cdot Min(\omega), i = \{1, 2, 3, 4\} \quad (18)$$

其中, $Min(\omega)$ 是调度工作流 ω 的最小数据传输时延, r_i 则是从集合 $\{1, 1.5, 3, 5\}$ 中依次取值,表示 $TimeLimit(\omega)$ 从紧张到宽松。 $TimeLimit(\omega)$ 中默认 $r_i = 1.5$ 。

科学工作流隐私数据集比例约占总数据集的 20%,不同数据中心间的带宽(单位是 M/s)表示如下:

$$Bandwidth = \begin{bmatrix} \sim & 10 & 20 \\ 10 & \sim & 150 \\ 20 & 150 & \sim \end{bmatrix}$$

根据 Amazon 官方网站数据,私有云到公有云的传输代价为 0.2(\$/GB),而私有云之间不计传输代价。Amazon 公有云存储代价为 0.02(\$/GB)。根据文献[20],将私有云存储代价定为公有云的 20 倍,即 0.4(\$/GB)。

为了对比基于 GAPSO 算法的数据布局策略的有效性,我们改进了文献[26]的基于遗传算法的数据布局策略,使之可以适应于本文的问题模型。同时,加入随机布局与本文策略进行对比。

4.2 结果分析

由于算法结果具有不唯一性,每个算法对每个工作流运行 100 组数据取平均值。

图 2 是默认实验环境下两种不同规模大小的科学工作流在不同算法下的执行代价。总体上来看,无论是小型、中型、还是大型工作流,GA 算法与本文的 GAPSO 算法相比随机布局,均能取得更好的数据布局结果,其数据布局产生的数据布局代价平均只有随机布局结果的 30%~40%。而本文的 GAPSO 算法在数据布局代价上略优于 GA 算法,其主要原因

是遗传算法策略每次迭代的搜索范围较为固定,且没有充分考虑每一代的个体情况,导致遗传算法在搜索后期效率低下且过早收敛。而本文 GAPSO 算法既注重了种群每一代之间的进化过程,又注重了优秀个体的保留与再成熟,解决了传统遗传算法的过早收敛问题,提高了种群多样性,因此平均数据布局代价要略低于 GA 算法。

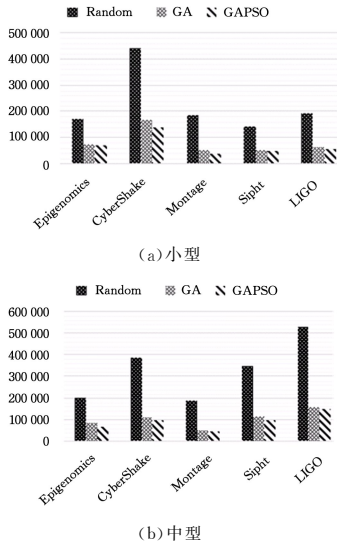


图2 不同规模的科学工作流在不同算法下的执行代价

另外,对比图2(a)和图2(b)可以看出,科学工作流数据布局代价与科学工作流规模成一定正比,其原因是科学工作流的任务数量增加的同时,科学工作流包含的数据集个数、数据大小总量及任务与数据之间的复杂程度也在不断增加,且同规模不同种类的科学工作流数据布局代价也有较大差异,因为不同种类的科学工作流结构各异,即使任务量相差不多,但其所携带的数据集数量、数据集大小以及数据依赖的复杂程度均会很大程度上影响数据布局代价。

为观察不同传输时延约束对科学工作流数据布局代价的影响,我们选取 Epigenomics 中型科学工作流来观察从紧张到宽松的传输时延约束下的科学工作流数据布局代价。

图3是中型 Epigenomics 科学工作流在4种不同传输时延约束下的数据布局代价。从图中可以看出,随着传输时延约束从紧张到宽松,数据布局代价越来越低,这是因为当传输时延约束紧张时,我们不得不将更多的数据集存放到私有云数据中心以更多地使用私有云数据中心间的传输带宽,虽然单位容量的数据传输代价与数据存储代价相差不大,但科学工作流数据布局产生的数据传输大小要远小于数据存储大小,而私有云的数据存储成本远大于公有云的数据存储成本,所以会产生较高的数据布局代价。




图3 不同传输时延约束下的 Epigenomics 数据布局代价

结束语 合理有效的科学工作流数据布局方案能够大量减少数据传输时延,降低数据布局代价,节省成本。针对科学工作流在混合云中执行会产生大量的跨数据中心传输,造成

严重的传输时延及代价问题,本文提出了一种基于 GAPSO 算法的混合云环境数据布局策略。本文考虑混合云环境下数据布局特点,提出一种基于遗传粒子群优化混合算法(GAPSO)的数据布局策略,目的是优化科学工作流数据传输与存储代价。该方法通过考虑公有云数据中心与私有云数据中心的的不同特点等因素,以及数据传输时延约束对数据传输与存储代价的影响,结合遗传算法与粒子群优化算法的优点,有效减少了数据传输与存储代价。实验结果表明,GAPSO 算法可以更加有效地节省混合云环境下数据布局产生的代价,且随着传输时延约束越来越宽松,数据布局代价也会相应减少。

未来工作将会考虑数据中心间的带宽波动以及服务提供商对网络资源与存储资源的要价方式,这些因素会影响到数据布局的最终结果。

参考文献

- [1] SZABO C, SHENG Q Z, KROEGER T, et al. Science in the Cloud: Allocation and Execution of Data-Intensive Scientific Workflows[J]. Journal of Grid Computing, 2014, 12(2): 245-264.
- [2] WEISS A. Computing in the clouds [J]. Networker, 2007, 11(4): 16-25.
- [3] ZHANG X, ZHANG Y, ZHAO X, et al. SmartRelationship: a VM relationship detection framework for cloud management [C]// Asia-pacific Symposium on Internetwork. 2014.
- [4] CHEN X, ZHANG Y, ZHANG X, et al. Towards runtime model based integrated management of cloud resources [C]// Asia-pacific Symposium on Internetwork. ACM, 2013.
- [5] ZHANG X, CHEN X, ZHANG Y, et al. Runtime Model Based Management of Diverse Cloud Resources [C]// International Conference on Model Driven Engineering Languages and Systems. Springer, Berlin, Heidelberg, 2013.
- [6] HUANG G, CHEN X, ZHANG Y, et al. Towards Architecture-based Management of Platforms in Cloud [J]. 中国计算机科学前沿(英文版), 2012, 6(4): 388-397.
- [7] ABRISHAMI H, REZAEIAN A, TOUSI G K, et al. Scheduling in hybrid cloud to maintain data privacy [C]// Fifth International Conference on Innovative Computing Technology. IEEE, 2015: 83-88.
- [8] AN B, ZHANG X, TSUGAWA M, et al. Towards a Model-Defined Cloud-of-Clouds [C]// Collaboration & Internet Computing. IEEE, 2016.
- [9] ARMBRUST M, FOX A, GRIFFITH R, et al. Above the clouds: A Berkeley view of cloud computing [R]. No. UCB/EECS-2009-28, Berkeley, Department of Electrical Engineering and Computer Sciences, University of California, 2009.
- [10] FU J, WANG J C, LU J, et al. Research on meteorology indices forecasting framework based on hybrid cloud computing platforms [C]// Proc. of the Ubiquitous Information Technologies and Applications. Netherlands: Springer-Verlag, 2013: 727-735.
- [11] 陈晓, 赵晶玲. 大数据处理中混合型聚类算法的研究与实现 [J]. 信息安全, 2015(4): 45-49.
- [12] YUAN D, YANG Y, LIU X, et al. A data placement strategy in scientific cloud workflows [J]. Future Generation Computer Systems, 2010, 26(8): 1200-1214.

影响接收线圈间互感系数的因素。最终得出,接收线圈间距离、角度和高度直接影响接收线圈间的互感系数。

基于磁耦合谐振 WRSNs 一对二的充电过程,实验分析接收线圈间距离、角度和高度 3 个因素对接收线圈间互感影响,得出接收线圈间距离和高度与接收能量效率和功率成正比,接收线圈角度与接收能量效率和功率成反比。实验结果表明,位于同侧的接收线圈间互感系数对接收节点能量传输的影响较大。

参考文献

- [1] KURS A, KARALIS A, MOFFATT R, et al. Wireless power transfer via strongly coupled magnetic resonances[J]. *Science*, 2007, 317(5834): 83-86.
- [2] XU W Z, LIANG W F, JIA X H, et al. Maximizing Sensor Lifetime with the Minimal Service Cost of a Mobile Charger in Wireless[J]. *IEEE Transactions on Mobile Computing*, 2018, 17(11): 2564-2577.
- [3] GUO S T, WANG C, YANG Y Y. Joint mobile data gathering and energy provisioning in wireless rechargeable sensor networks [J]. *IEEE Transactions on Mobile Computing*, 2014, 13(12): 2836-2852.
- [4] KURS A, MOFFATT R, SOLJACIĆ M. Simultaneous mid-range power transfer to multiple devices[J]. *Applied Physics Letters*, 201096(4): 044102-044104.
- [5] KIM J W, SON H C, KIM D H, et al. Analysis of wireless energy transfer to multiple devices using CMT[C]// *Asia-Pacific Microwave Conference Proceedings (APMC)*. Yokohama, 2010: 2149-2152.
- [6] KHELLADI L, DJENOURI D, LASLA N, et al. MSR; Minimum-Stop Recharging Scheme for Wireless Rechargeable Sensor Networks[C]// *IEEE International Conference on Ubiquitous Intelligence and Computing (UIC)*. Denpasar, Bali, Indonesia, 2014: 378-383.
- [7] SHI Y, XIE L, HOU Y T, et al. On renewable sensor networks with wireless energy transfer[C]// *IEEE INFOCOM*. Shanghai, 2011: 1350-1358.
- [8] AHN D, HONG S. Effect of Coupling Between Multiple Transmitters or Multiple Receivers on Wireless Power Transfer[J]. *IEEE Transactions on Industrial Electronics*, 2013, 60(7): 2602-2613.
- [9] 张波, 张青. 两个负载接收线圈的谐振耦合无线输电系统特性分析[J]. *华南理工大学学报(自然科学版)*, 2012, 40(10): 152-158.
- [10] 皇甫国庆. 两圆线圈间互感及耦合系数讨论[J]. *渭南师范学院学报*, 2015(14): 24-29.
- [11] 陈俊斌, 朱霞. 任意同轴圆线圈互感系数的近似解析公式[J]. *后勤工程学院学报*, 2010, 26(5): 86-91.
- [12] 罗垚, 陈柏超, 袁佳歆, 等. 倾斜轴空心矩形截面圆柱线圈互感计算[J]. *电工技术学报*, 2012, 27(5): 132-136.
- [13] BABIC S I, AKYEL C. Calculating Mutual Inductance Between Circular Coils With Inclined Axes in Air[J]. *IEEE Transactions on Magnetics*, 2008, 44(7): 1743-1750.
- [14] 李荣华. 测定互感器互感系数的方法[J]. *实验技术与管理*, 2005, 22(8): 33-35.
- [15] (上接第 358 页)
- [13] DENG K, REN K, ZHU M, et al. A Data and Task Co-scheduling Algorithm for Scientific Cloud Workflows[J]. *IEEE Transactions on Cloud Computing*, 2015: 1-1.
- [14] WANG M, ZHANG J, DONG F, et al. Data Placement and Task Scheduling Optimization for Data Intensive Scientific Workflow in Multiple Data Centers Environment[C]// *International Conference on Advanced Cloud & Big Data*. IEEE, 2014: 77-84.
- [15] 程慧敏, 李学俊, 吴洋, 等. 云环境下基于多目标优化的科学 workflow 数据布局策略[J]. *计算机应用与软件*, 2017, 34(3): 1-6.
- [16] 王东亮, 衣俊艳, 李时慧, 等. 融合负载均衡和蝙蝠算法的云计算任务调度[J]. *信息安全学报*, 2017(1): 23-28.
- [17] ZHAO Q, XIONG C, ZHAO X, et al. A Data Placement Strategy for Data-Intensive Scientific Workflows in Cloud[C]// *IEEE/ACM International Symposium on Cluster, Cloud and Grid Computing*. IEEE, 2015: 928-934.
- [18] ZHANG X X, HU Z G, ZHENG M G, et al. A novel cloud model based data placement strategy for data-intensive application in clouds[J]. *Computers and Electrical Engineering*, 2018.
- [19] 彭晓波, 桂卫华, 黄志武, 等. GAPSO: 一种高效的遗传粒子混合算法及其应用[J]. *系统仿真学报*, 2008, 20(18): 5025-5031.
- [20] 马小平. 私有云存储系统的设计与实现[D]. 成都: 电子科技大学, 2014.
- [21] 林兵, 郭文忠, 陈国龙. 多云环境下带截止日期约束的科学 workflow 调度策略[J]. *通信学报*, 2018, 39(1): 56-69.
- [22] KENNEDY J, EBERHART R. Particle swarm optimization [C]// *IEEE International Conference on Neural Networks*. IEEE, 2002: 1942-1948.
- [23] HOLLAND J H. *Adaptation in Natural and Artificial Systems* [M]. Ann Arbor, Michigan: University of Michigan Press, 1975.
- [24] SHI Y, EBERHART R. A modified particle swarm optimizer [C]// *IEEE International Conference on Evolutionary Computation Proceedings*. IEEE World Congress on Computational Intelligence, 1998: 69-73.
- [25] BHARATHI S, CHERVENAK A, DEELMAN E, et al. Characterization of scientific workflows [C]// *Third Workshop on Workflows in Support of Large-Scale Science*. IEEE, 2008: 1-10.
- [26] CUI L, ZHANG J, YUE L, et al. A Genetic Algorithm Based Data Replica Placement Strategy for Scientific Applications in Clouds[J]. *IEEE Transactions on Services Computing*, 2015.