

Программный пакет децентрализованного обслуживания потоков параллельных задач в пространственно-распределённых вычислительных системах^{*)}

М. Г. Курносов, А. А. Пазников

Рассматриваются децентрализованные алгоритмы и программы обслуживания потоков параллельных задач в пространственно-распределённых вычислительных системах (ВС). Описывается функциональная структура разработанного программного пакета GBroker децентрализованной диспетчеризации параллельных MPI-программ в пространственно-распределённых мультикластерных ВС. Приводятся результаты моделирования на действующей мультикластерной ВС.

Ключевые слова: диспетчеризация параллельных программ, пространственно-распределённые вычислительные системы, GRID-системы

1. Введение

При решении сложных задач науки и техники широкое применение получили пространственно-распределённые вычислительные системы (ВС) – макроколлективы рассредоточенных вычислительных средств (подсистем), взаимодействующих между собой через локальные и глобальные сети связи (включая сеть Internet) [1, 2]. К таким системам относятся GRID-системы и мультикластерные ВС.

При организации функционирования пространственно-распределённых ВС возникает задача диспетчеризации параллельных программ, поступающих в систему. Для каждой программы необходимо определить, на каких вычислительных ресурсах каких подсистем она будет выполняться. В средствах диспетчеризации должны учитываться динамичность состава систем и переменная загрузка их вычислительных ресурсов.

Централизованные средства диспетчеризации имеют существенный недостаток: отказ управляющего узла может привести к неработоспособности всей ВС. Кроме того, в случае применения таких средств в большемасштабных ВС возрастают временные затраты на поиск требуемых ресурсов. Поэтому актуальной является задача разработки децентрализованных моделей, алгоритмов и программного обеспечения диспетчеризации параллельных задач в распределённых ВС.

При децентрализованной схеме диспетчеризации в вычислительной системе функционирует коллектив диспетчеров, осуществляющий поиск необходимых ресурсов для задач. Это позволяет достичь живучести и в большемасштабных ВС, то есть способности продолжать работу при отказах отдельных компонентов и подсистем.

^{*)} Работа выполнена в рамках интеграционного проекта № 113 СО РАН и при поддержке РФФИ (гранты № 08-07-00018, 09-07-13534, 09-07-90403, 09-07-12016) и Совета по грантам Президента РФ для поддержки ведущих научных школ (грант НШ-5176.2010.9).

Существует несколько пакетов централизованной диспетчеризации параллельных программ в пространственно-распределённых системах: GridWay, Common Scheduler Framework (CSF), Nimrod/G, Condor-G, GrADS, AppLeS, DIRAC, WMS и др. В пакете GridWay [3, 4] преследуется цель минимизации времени обслуживания задач, при этом учитывается время решения задачи и её пребывания в очереди; реализован механизм миграции задач между подсистемами. Среда CSF [5] предоставляет средства резервирования ресурсов на основе алгоритма Round-Robin и алгоритмов, созданных пользователем. В основе Nimrod/G [6] лежит экономическая модель, целью которой является поиск равновесного состояния между поставщиками и потребителями ресурсов посредством механизма аукциона. Диспетчер Condor-G [7], являющийся развитием системы Condor, ориентирован на использование в системах высокой пропускной способности (High-throughput Computing) и основан на алгоритмах Matchmaking и ClassAd. Предполагается, что пользователь самостоятельно выбирает подсистему из списка доступных; при этом поддерживается возможность создания пользовательских диспетчеров. Функционирование диспетчера WMS [8], используемого в GRID-проекте Enable Grid for e-Science, основывается на применении двух алгоритмов: либо задача отправляется на подсистему для решения как можно быстрее, либо задача ожидает в очереди до тех пор, пока ресурс не станет доступным. В DIRAC [9] на подсистемах установлены агенты, которые при освобождении ресурсов запрашивают задачи из глобальных очередей.

В данной работе предлагаются децентрализованные алгоритмы и программное обеспечение диспетчеризации параллельных программ в пространственно-распределённых вычислительных и GRID-системах.

2. Постановка задачи

Пусть имеется пространственно-распределённая ВС, состоящая из H подсистем; N – суммарное количество элементарных машин (ЭМ) в подсистемах. Обозначим через n_i количество ЭМ, входящих в состав подсистемы $i \in S = \{1, 2, \dots, H\}$. Пусть также $b_{ij} = b(i, j, m)$ – пропускная способность канала связи между подсистемами $i, j \in S$ при передаче сообщений размером m байт ($[b(i, j, m)]$ = байт/с).

В каждой подсистеме присутствует диспетчер, который поддерживает очередь параллельных задач и осуществляет поиск вычислительных ресурсов для их выполнения (рис. 1).



Рис. 1. Пример локальных окрестностей диспетчеров:

$$H = 4, L(1) = \{3, 4\}, L(2) = \{3, 4\}, L(3) = \{1, 2\}, L(4) = \{1, 2\}$$

Коллектив диспетчеров представлен в виде ориентированного графа $G = (S, E)$, в котором вершинам соответствуют диспетчеры, а рёбрам – логические связи между ними. Нали-

чие дуги $(i, j) \in E$ в графе означает, что диспетчер i может отправлять ресурсные запросы (задачи из своей очереди) диспетчеру j . Множество всех вершин j , смежных вершине i , образуют её локальную окрестность $L(i) = \{j \in S : (i, j) \in E\}$.

Пользователь направляет задачу и запрос на выделение ресурсов одному из диспетчеров. Диспетчер (в соответствии с реализованным в нём алгоритмом) осуществляет поиск (суб)оптимальной подсистемы $j^* \in S$ для выполнения задачи пользователя.

Считаем, что задача характеризуется рангом r – количеством параллельных ветвей, ожидаемым временем t выполнения программы (Walltime) и суммарным размером z исполняемых файлов и данных ($[z]$ = байт). Рассмотрим децентрализованный алгоритм обслуживания потоков параллельных задач в пространственно-распределённых ВС.

3. Децентрализованный алгоритм диспетчеризации параллельных задач

При поступлении программы пользователя в очередь подсистемы $i \in S$ её диспетчер выполняет следующий алгоритм.

1. У каждого диспетчера $j \in L(i) \cup \{i\}$ запрашивается оценка времени t_j , через которое программа может быть запущена на ресурсах подсистемы j в случае передачи программы в её очередь.

2. Через систему мониторинга определяется текущее значение пропускной способности $b_{ij} = b(i, j, z)$ канала связи между подсистемами i и j .

3. Отыскивается оценка времени $t(i, j)$ обслуживания программы в случае её перенаправления в очередь подсистемы j . Время обслуживания включает в себя время доставки исполняемых файлов и данных до подсистемы j , время ожидания t_j в очереди подсистемы и время t выполнения программы:

$$t(i, j) = z / b_{ij} + t_j + t.$$

4. Программа перенаправляется в очередь подсистемы j^* , в которой достигается минимальное значение времени $t(i, j)$ обслуживания параллельной программы

$$j^* = \arg \min_{j \in L(i) \cup \{i\}} \{t(i, j)\}.$$

Диспетчер выполняет описанный алгоритм поиска подсистем при наступлении одного из нижеследующих событий.

1. Поступление новой задачи в очередь от пользователя.

2. Удаление задачи из очереди, начало выполнения задачи, изменение параметров (количества ветвей, времени решения) одной или нескольких задач в очереди. (Перечисленные события влекут за собой поиск новых подсистем для задач, стоящих в очереди после задач с модифицированными параметрами и состояниями).

3. Окончание временного интервала Δ с момента последнего запуска алгоритма поиска подсистем.

Периодический поиск подсистем для задач в очереди позволяет учесть динамически изменяющуюся загрузку ресурсов пространственно-распределённых вычислительных и GRID-систем. Описанный подход реализован в программном пакете GBroker децентрализованной диспетчеризации параллельных MPI-программ в пространственно-распределённых мультикластерных ВС.

4. Программный пакет GBroker

В Центре параллельных вычислительных технологий ГОУ ВПО “Сибирский государственный университет телекоммуникаций и информатики” (ЦПВТ ГОУ ВПО “СибГУТИ”) и Лаборатории вычислительных систем Института физики полупроводников им. А.В. Ржанова СО РАН (ИФП СО РАН) создан и развивается программный пакет GBroker [10] децентрализованной диспетчеризации параллельных MPI-программ в пространственно-распределённых ВС. Пакет разработан на языке ANSI C для операционной системы GNU/Linux.

В пакет (рис. 2) входят диспетчер gbroker, клиентское приложение gclient и средство мониторинга производительности каналов связи netmon между подсистемами на уровне стека протоколов TCP/IP.




Рис. 2. Функциональная структура пакета GBroker

Модуль gbroker устанавливается на каждой из подсистем и на основе расширяемой архитектуры обеспечивает интерфейс с локальной системой пакетной обработки заданий (на данный момент – TORQUE). Модуль netmon устанавливается вместе с gbroker на подсистемах. Взаимодействуя друг с другом, сервисы netmon собирают информацию о производительности каналов связи между подсистемами. Модуль gclient реализует интерфейс между пользователем и системой.

Администратор настраивает локальные окрестности диспетчеров gbroker, указывая, какие диспетчеры с какими могут обмениваться задачами из своих очередей, и настраивает сервис netmon.

Пользователь формирует задание, состоящее из параллельной MPI-программы и паспорта на языке ресурсных запросов JSDL (Job Submission Description Language), и отправляет его средствами gclient любому из диспетчеров gbroker. Диспетчер в соответствии с описанным алгоритмом выбирает подсистему, на которой должна выполняться задача.

5. Моделирование алгоритмов

Созданный инструментарий децентрализованной диспетчеризации параллельных задач исследован на действующей мультикластерной ВС, созданной ЦПВТ ГОУ ВПО “СибГУТИ” совместно с Лабораторией ВС ИФП СО РАН. В экспериментах использовано 3 сегмента мультикластерной ВС (рис. 3):

- кластер Xeon16: 4 узла (2 x Intel Xeon 5150, 16 процессорных ядер);
 - кластер Xeon32: 4 узла (2 x Intel Xeon 5345, 32 процессорных ядра);
 - кластер Xeon80: 10 узлов (2 x Intel Xeon 5420, 80 процессорных ядер).
- Сеть связи между сегментами ВС Fast Ethernet.

На сегментах системы был установлен пакет Gbroker и настроен компонент netmon (рис. 3). В локальную окрестность каждого диспетчера были включены диспетчеры всех кластеров.




Рис. 3. Тестовая конфигурация пространственно-распределённой мультикластерной ВС: $H = 3$

В качестве тестовых задач использовались MPI-программы из пакета NAS Parallel Benchmarks (NPB). Моделирование проводилось следующим образом. На выбранную подсистему поступал стационарный поток из M параллельных задач. Тестовые задачи выбирались псевдослучайным образом. Ранг r_i параллельной программы генерировался в соответствии с распределением Пуассона со значениями математического ожидания $r \in \{4, 8, 12, 16\}$. Задачи поступали в очередь диспетчера кластера Xeon80 через интервалы времени t , экспоненциально распределённые со значениями интенсивности $\lambda = \{0.1; 0.2; 0.3; 0.4\}$, $[\lambda] = c^{-1}$.

Обозначим через t_i – момент времени поступления задачи $i \in \{1, 2, \dots, M\}$ на вход диспетчера, t'_i – момент времени начала решения задачи i , t''_i – момент завершения решения задачи i . Тогда суммарное время τ обслуживания (ожидания в очереди и решения) M задач составит

$$\tau = \max_{i=1,2,\dots,M} t''_i - \min_{i=1,2,\dots,M} t_i.$$

Для оценки эффективности алгоритма диспетчеризации использовались следующие показатели:

– среднее время T обслуживания задачи

$$T = 1/M \sum_{i=1}^M (t''_i - t_i),$$

– среднее время W пребывания задачи в очереди

$$W = 1/M \sum_{i=1}^M (t'_i - t_i),$$

– пропускная способность B системы

$$B = M / \tau.$$

На рис. 4 показана зависимость среднего времени обслуживания параллельных задач от интенсивности их поступления в систему.




Рис. 4. Зависимости среднего времени T обслуживания задачи от интенсивности λ потока задач:

$$1 - r = 4; 2 - r = 8; 3 - r = 12; 4 - r = 16$$

Из графиков видно, что среднее время обслуживания задачи увеличивается с ростом интенсивности потока поступления задач. Это связано с образованием очередей задач на подсистемах ВС. Такое влияние интенсивности потока особенно значительно при рангах параллельных программ, близких к количеству процессорных ядер в подсистемах.

Среднее время W пребывания задачи в очереди незначительно (рис. 5) по сравнению с суммарным временем её обслуживания и в среднем не превосходит одной секунды (для рассматриваемой конфигурации ВС). Среднее время пребывания задачи в очереди не изменяется существенно как с ростом интенсивности потока поступления задач, так и с увеличением среднего ранга параллельных задач.




Рис. 5. Зависимости среднего времени W пребывания задачи в очереди от интенсивности λ потока задач:

$$1 - r = 4; 2 - r = 8; 3 - r = 12; 4 - r = 16$$

Пропускная способность системы (рис. 6) растёт при увеличении интенсивности потока поступления задач. При больших значениях интенсивности происходит снижение пропуск-

ной способности системы, что связано с образованием очередей на подсистемах. С увеличением среднего ранга задач это влияние интенсивности на пропускную способность системы усиливается.




Рис. 6. Зависимости пропускной способности B системы от интенсивности λ потока задач:

$$1 - r = 4; 2 - r = 8; 3 - r = 12; 4 - r = 16$$

6. Заключение

Централизованные системы диспетчеризации большемасштабных распределённых ВС характеризуются вычислительной сложностью поиска требуемых ресурсов. Децентрализованная диспетчеризация распределённых вычислительных и GRID-систем существенно проще централизованной позволяет повысить их живучесть.

Децентрализованная диспетчеризация параллельных задач в распределённых вычислительных и GRID-системах позволяет повысить их живучесть. Кроме того, применение централизованных систем диспетчеризации в большемасштабных ВС ограничено вычислительной сложностью поиска требуемых ресурсов.

Результаты исследования созданного инструментария диспетчеризации параллельных MPI-программ на мультикластерной ВС показали, что среднее время обслуживания задачи и при децентрализованной, и при централизованной диспетчеризации сопоставимы. Время диспетчеризации достаточно мало по сравнению со временем выполнения задач. Инструментарий децентрализованной диспетчеризации – один из необходимых компонентов обеспечения живучести пространственно-распределённой мультикластерной ВС ЦПВТ ГОУ ВПО “СибГУТИ” и Лаборатории ВС ИФП СО РАН.

Литература

1. Хорошевский В.Г. Архитектура вычислительных систем. – М.: МГТУ им. Н.Э. Баумана, 2008. – 520 с.
2. Евреинов Э.В., Хорошевский В.Г. Однородные вычислительные системы. – Новосибирск: Наука, 1978. – 320 с.
3. R. Montero, E. Huedo, I. Llorente. Grid Resource Selection for Opportunistic Job Migration // 9th International Euro-Par Conference. – 2003. – V. 2790. – P. 366-373.
4. E. Huedo, R. Montero, I. Llorente. A Framework for Adaptive Execution on Grids // Software – Practice and Experience (SPE). – 2004. – V. 34 – P. 631-651
5. W. Xiaohui, D. Zhaohui, Y. Shutao. CSF4: A WSRF Compliant Meta-Scheduler // In Proc. of World Congress in Computer Science Computer Engineering, and Applied Computing. – 2006. – P. 61-67.

6. R. Buyya, D. Abramson, J. Giddy. Nimrod/G: An architecture for a resource management and scheduling system in a global computational Grid // Proceedings of the 4th International Conference on High Performance Computing in Asia-Pacific Region. – 2000. – P. 283-289.
7. J. Frey, T. Tannenbaum, M. Livny, I. Foster, S. Tuecke. Condor-G: A Computation Management Agent for Multi-Institutional Grids // Cluster Computing. – 2001. – V. 5. – P. 237-246.
8. P. Andreetto, S. Borgia, A. Dorigo. Practical approaches to grid workload and resource management in the EGEE project // In CHEP '04: Proceedings of the Conference on Computing in High Energy and Nuclear Physics. – 2004. – V. 2. – P. 899-902.
9. E. Caron, V. Garonne, A. Tsaregorodtsev. Evaluation of Meta-scheduler Architectures and Task Assignment Policies for High Throughput Computing // Technical report. Institut National de Recherche en Informatique et en Automatique. – 2005.
10. Курносов М.Г., Пазников А.А. Децентрализованная диспетчеризация параллельных программ в распределённых вычислительных системах // Труды 9 Международной конференции “Высокопроизводительные параллельные вычисления на кластерных системах” (НПС-2009). – Казань : КГТУ им. А.Н. Туполева, 2009. – С. 260-265.

Статья поступила в редакцию 15.05.2010

Курносов Михаил Георгиевич

Кандидат технических наук, доцент Кафедры вычислительных систем Сибирского государственного университета телекоммуникаций и информатики, младший научный сотрудник Лаборатории вычислительных систем Института физики полупроводников им. А.В. Ржанова СО РАН. Область научных исследований – модели и методы организации функционирования большемасштабных распределённых вычислительных систем.

Тел.&факс: (383) 330-56-26, 269-82-75; e-mail: mkurnosov@gmail.com

Пазников Алексей Александрович

Магистрант Кафедры вычислительных систем ГОУ ВПО “СибГУТИ”. Область научных исследований – модели и методы организации функционирования большемасштабных пространственно-распределённых вычислительных и GRID-систем.

Тел.: +7 923 243 9242; e-mail: apaznikov@gmail.com

Decentralized service of parallel job streams in geographically-distributed computer systems

M. Kurnosov, A. Paznikov

Parallel job streams servicing problem in geographically-distributed computer systems is considered. Functional structure of developed program tools of decentralized service of parallel MPI-jobs in multicluster computer systems are described. Results of experiments on multicluster computer system are represented.

Keywords: parallel program scheduling, brokering, geographically-distributed computer systems, GRID-systems.