

# **РЕАЛИЗАЦИЯ УНИФИЦИРОВАННОГО ДОСТУПА К ИНФОРМАЦИИ О СОСТОЯНИИ МУЛЬТИКЛАСТЕРА В ПРОГРАММНОМ КОМПОНЕНТЕ УПРАВЛЕНИЯ ПЛАТФОРМАМИ ИСПОЛНЕНИЯ MCMS**

**В.Д. Кустикова**

## **Введение**

При использовании вычислительных кластеров большое значение имеет правильное распределение нагрузки по узлам, в особенности, если кластер обладает неоднородной структурой: различается производительность вычислительных узлов, объем установленной в них оперативной памяти, характеристики сетевых соединений.

Планировщик заданий - компонент, отвечающий за построение расписания запуска заданий на имеющихся вычислительных ресурсах. Как правило, он входит в состав системы управления кластером, но в ряде случаев допускается возможность подключения планировщиков сторонних разработчиков. Для принятия решений планировщику необходима информация о составе и характеристиках аппаратных средств кластера (статический компонент), а также об их текущей загруженности (динамический компонент).

Данная работа посвящена задаче обеспечения планировщика статической и динамической информацией и способе ее решения в программном компоненте управления платформами исполнения Multi-Cluster Management System (MCMS), реализованном в ННГУ в рамках выполнения ОКР по теме "Разработка высокопроизводительного программного комплекса для квантово-механических расчетов и моделирования наноразмерных атомно-молекулярных систем и комплексов".

## **Стратегии планирования**

Основная задача планировщика - оптимальным образом определить набор узлов для запуска пользовательских приложений на основании информации о запрашиваемых и доступных ресурсах. При этом под оптимальностью решения понимается достижение в процессе функционирования многопроцессорной системы некоторой цели. В зависимости от специфики заданий, которые попадают на исполнение на кластер, и количества имеющихся вычислительных ресурсов в качестве цели часто выделяют минимизацию среднего времени ожидания задачи в очереди либо минимизацию числа незанятых ресурсов в каждый момент времени.

При решении задачи планирования используется стратегия распределения задач, обычно вводящая дополнительные характеристики задач и политики выбора узлов, а также расширяющая список требований к данным, необходимым для принятия решения. Наиболее распространены следующие стратегии:

- списочные алгоритмы (First Come First Served – FCFS и его модификации) [1];
- алгоритм обратного заполнения (Backfill) [2];
- алгоритм Gang Scheduling [3], [4];
- алгоритм, использующий множество очередей (feedback algorithm) [5];
- генетические алгоритмы;
- смешанные алгоритмы.

Модификации перечисленных алгоритмов планирования могут предоставлять пользователю возможность определять для задачи необходимый минимальный размер оперативной памяти на узле, объем свободного пространства на жестком диске и другие параметры и ограничения, что требует наличия дополнительной информации об имеющихся вычислительных ресурсах.

В реальных системах планирования кластерных ресурсов наибольшее распространение получили алгоритмы FCFS (или его модификация – Priority FCFS) и Backfill.

## **Средства мониторинга вычислительных ресурсов**

Планировщику для выполнения итерации планирования необходима актуальная информация о состоянии вычислительных ресурсов. Эти данные предоставляются планировщику средствами мониторинга вычислительных ресурсов. Рис. 1 представляет частичный список характеристик, которые предоставляются рядом существующих средств мониторинга, входящих в состав систем управления кластером или работающими независимо.

Имя характеристики	Ganglia [6]	Cacti [7]	Nagios [8]	Hyperic [9] (доступные метрики под Linux)	Средства Windows HPC Server 2008 [10],[11]	Средства Torque [12]
Имя/ip-адрес узла	+	+	+	+	+	+
Состояние узла	-	+	+	+	+	+
Количество ядер	+	-	?	?	+	+
Количество принятых и отправленных бит/байт по сети за некоторый промежуток времени	+	+	+	+	+	+
Размер свободного пространства на жестком диске	+	-	+	-	+	+
Общий размер жесткого диска	+	-	+	-	- (?)	+
Размер оперативной памяти	+	-	?	-	- (?)	+
Размер доступной оперативной памяти	+	-	?		+	+
Количество работающих процессов в системе	+	-	-	-	-	-
Общее количество процессов в системе	+	+	-	+	-	-
Проверка активности процесса с указанным именем	-	-	+	-	-	-
Средний процент загрузки процессора в течение фиксированного времени	+	+	+	+	+	+
Время последней загрузки системы	+	-	-	-	+	-
Процентостояния процессора или процессоров	+	-	?	+	-	-
Тактовая частота процессора	+	-	?		+	-
Максимальный размер файла подкачки	+	-	+	+	-	+
Размер свободного свопа	+	-	+	+	-	-

Рис. 1. Некоторые характеристики узлов, предоставляемые различными средствами мониторинга

Из приведенных данных видно, что независимые средства мониторинга предоставляют значительно более широкий спектр метрик по сравнению со средствами,строенными в системы управления. Необходимо отметить, что в таблице приведен не полный перечень предоставляемых характеристик, в частности, некоторые средства ориентированы на мониторинг различных сетевых интерфейсов и предоставляют набор соответствующих метрик.

Все рассматриваемые средства мониторинга, за исключением средств Microsoft Windows HPC Server 2008, являются свободно распространяемыми, либо для них существует Community-версия, что позволяет попробовать их в практическом использовании. В частности, нас интересуют предоставляемые ими интерфейсы для получения данных.

Рассматриваемые средства мониторинга предоставляют различные механизмы взаимодействия для получения информации о вычислительных ресурсах:

- Ganglia позволяет использовать TCP/IP или UDP протокол для получения информации в формате XML, а также включает Web-интерфейс.
- Nagios имеет командный интерфейс и Web-интерфейс.
- Cacti предоставляет доступ по протоколу SNMP для выдачи сообщений фиксированного формата, а также реализует графический интерфейс для отображения результатов мониторинга.
- Enterprise-версия Hyperic предоставляет Java-ориентированный программный интерфейс, а также Web-интерфейс.
- Microsoft Windows HPC Server 2008 поддерживает графический, командный, программный (COM для приложений на C++, .NET APIs для приложений на .NET) интерфейсы и Microsoft Powershell.
- Torque поддерживает командный интерфейс.

Необходимо отметить, что в рамках одного средства различные интерфейсы могут предоставлять различный набор метрик, например, Microsoft PowerShell позволяет получить средний процент загрузки сетевых интерфейсов в то время, как командный интерфейс такой информации не предоставляет.

### Характеристики узлов, используемые планировщиками

Набор метрик, учитываемых планировщиком, определяется стратегией планирования. На рис. 2 представлены характеристики, используемые некоторыми компонентами планирования.

Имя характеристики	Maui [15]	Планировщик Windows HPC Server 2008	Планировщик Torque <sup>1</sup>	
	Backfilling	Priority FCFS	Backfilling	FCFS
Имя/ip-адрес узла	+	+	+	+
Название операционной системы	+	-	-	-
Состояние узла	+	+	+	+
Архитектура процессора	+	-	-	-
Количество ядер	+	+	+	+
Текущая загрузка процессора	+	-	-	-
Размер свободного пространства на жестком диске	+	-	-	-
Размер доступной оперативной памяти	+	-	-	+
Общий размер жесткого диска	+	-	-	-
Максимальное количество задач, которые могут одновременно работать на узле	+	-	+	-
Количество задач, которые одновременно работают на узле	+	-	+	-
Тактовая частота процессора	+	-	-	-

<sup>1</sup> Поддерживает возможность интеграции с некоторыми сторонними компонентами планирования. Например, планировщик может быть реализован разработчиком на процедурном языке BaSL или в скрипте, написанном на Tcl.

Рис. 2. Характеристики узлов, используемые компонентами планирования

Необходимо отметить, что совокупность используемых характеристик зависит от фактически используемой стратегии, в частности, настройки системы управления кластером определяют используемые планировщик (встроенный в систему или внешний) и алгоритм планирования, что и определяет совокупность необходимых характеристик.

### Программный компонент управления платформами исполнения

Цель создания программного компонента управления платформами исполнения MCMS состояла в обеспечении унифицированного доступа к совместно используемому множеству кластеров, обслуживаемых различными системами управления (мультиклUSTERУ). Архитектура MCMS представлена на рис. 3.

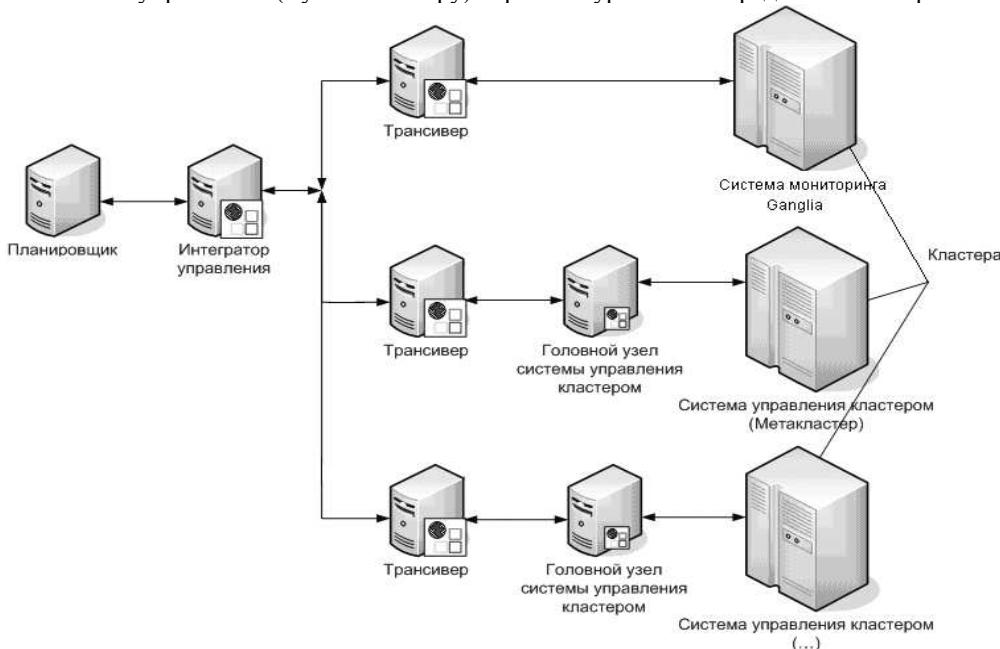


Рис. 3. Архитектура программного компонента управления платформами исполнения MCMS

MCMS состоит из двух основных модулей.

- Интегратор управления – web-сервис, предоставляющий унифицированный программный интерфейс управления мультиклUSTERом.

- Трансивер – модуль, который обеспечивает непосредственное взаимодействие с конкретной системой управления кластером (Microsoft Windows HPC Server 2008 [10], «Метакластер» [13], Torque [14]) или системой мониторинга ресурсов (Ganglia [6]).

Планировщик использует возможности MCMS и не входит в его состав.

Планировщик получает данные об аппаратных характеристиках и текущем состоянии узлов мультиклUSTERа в результате обращения к Интегратору управления, который ретранслирует запросы доступным трансиверам. Трансиверы получают значения характеристик для всех доступных узлов каждого кластера, используя соответствующий интерфейс взаимодействия с системой управления кластером или с системой мониторинга. В настоящий момент используются следующие механизмы доступа:

- трансивер Torque использует удаленный вызов команд интерфейса системы управления средствами удаленного терминала (ssh, [17]);
- трансивер Windows HPC Server 2008 использует программный интерфейс .NET API и командный интерфейс Windows PowerShell;
- трансивер Метакластера использует программный интерфейс .NET Remoting;
- трансивер Ganglia использует непосредственное TCP-соединение.

Совокупность предоставляемых характеристик фактически определяется суммарными ограничениями систем управления кластерами и мониторинга и в настоящий момент включает:

- характеристики кластера: имя кластера, количество узлов, топология сети, пропускная способность и латентность сетевых соединений (сетевые параметры не определяются автоматически и должны статически задаваться администратором);
- характеристики узла: DNS-имя узла, число ядер, частота и производительность ядер, объем оперативной памяти, список установленного программного обеспечения;
- состояние узла: текущий процент загрузки ядер, объем свободной физической памяти, текущий процент загрузки сетевых интерфейсов.

Перечисленный набор характеристик достаточен для реализации большинства стратегий планирования.

### **Заключение**

Разработанная компонента управления платформами исполнения MCMS ориентирована на взаимодействие с различными системами управления кластерами, системами мониторинга ресурсов и планировщиками. Компонента позволяет получать актуальную информацию об аппаратном составе и текущей загруженности узлов кластера, используя различные механизмы сопряжения с системами мониторинга ресурсов, и предоставляет планировщику совокупность информации, достаточную для работы большинства стратегий планирования.

Исследования выполнены в рамках ОКР по теме «Разработка высокопроизводительного программного комплекса для квантово-механических расчетов и моделирования наноразмерных атомно-молекулярных систем и комплексов» [16].

### **ЛИТЕРАТУРА:**

1. Saeed Iqbal, Rinku Gupta, Yung-Chin Fang. Planning Considerations for Job Scheduling in HPC Clusters // Dell Power Solutions, c. 133-136, 2005.
2. David Jackson, Quinn Snell, Mark Clement. Core Algorithms of the Maui Scheduler // Lecture Notes in Computer Science Job Scheduling Strategies for Parallel Processing: 7th International Workshop, JSSPP 2001, Cambridge, MA, USA, June 16, 2001. Revised Paper, Volume 2221, pp. 87-102, 2001, ISSN: 0302- 9743.
3. Uwe Schwiegelshohn, Ramin Yahyapour Improving First Come First Served job scheduling by gang scheduling // Computer Engineering Institute, University Dortmund, Germany: JSSPP'98, LNCS 1459, p. 180-198, 1998;
4. Julita Corbalan Gonzalez. Coordinated Scheduling and Dynamic Performance Analysis in Multiprocessor Systems - [[http://www.tdr.cesca.es/TESIS\\_UPC/AVAILABLE/TDX-0723102-094622/07Jcg07de08.pdf](http://www.tdr.cesca.es/TESIS_UPC/AVAILABLE/TDX-0723102-094622/07Jcg07de08.pdf)].
5. O. Senane, D. Simon, D. Robert. Feedback scheduling for real-time control of systems with communication delays // ETFA'03 9th IEEE International Conference on Emerging Technologies and Factory Automation, Lisbonne. Volume 2, 16-19. pp. 454 - 461 vol.2 , 2003.
6. Ganglia Monitoring System - [<http://ganglia.sourceforge.net/>].
7. Cacti: The Complete RRDTool-based Graphing Solution - [<http://www.cacti.net>].
8. Nagios - The Industry Standard in IT Infrastructure Monitoring - [<http://www.nagios.org>].
9. Systems Monitoring, Server Monitoring & Systems Management Software | Hyperic - [<http://www.hyperic.com>].
10. Windows HPC Server 2008 | Microsoft Supercomputing | Supercomputers - [<http://www.microsoft.com/hpc/en/us/>].
11. Understanding Job Scheduling Policies - [[http://technet.microsoft.com/en-us/library/dd197402\(WS.10\).aspx](http://technet.microsoft.com/en-us/library/dd197402(WS.10).aspx)].
12. Portable Batch System Administrators Guide – [[http://lsec.cc.ac.cn/chinese/lsec/doc/v2.3\\_admin.pdf](http://lsec.cc.ac.cn/chinese/lsec/doc/v2.3_admin.pdf)].
13. Система управления «Метакластер» – [[www.cluster.software.unn.ru](http://www.cluster.software.unn.ru)].

14. TORQUE Resource Manager – [<http://www.clusterresources.com/products/torque>].
15. Maui Cluster Scheduler – [<http://www.clusterresources.com/products/maui>].
16. В.Н. Васильев, А.В. Бухановский, С.А. Козлов, В.Г. Маслов, Н.Н. Розанов. Высокопроизводительный программный комплекс моделирования наноразмерных атомно-молекулярных систем // Научно-технический вестник. СПбГУ ИТМО «Технологии высокопроизводительных вычислений и компьютерного моделирования», № 54. СПб: Университетские телекоммуникации, 2008. С.3-13.17. SharpSSH - A Secure Shell (SSH) library for .NET – [<http://www.tamirgal.com/blog/page/SharpSSH.aspx>].