
Кластерные системы

Судаков А.А.

“Параллельные и распределенные
вычисления” Лекция 11

План

- История
 - Кластеры типа Beowulf
 - Кластеры типа MOSIX
 - Кластеры типа SSI
 - Балансирующие кластеры
 - Высоконадежные кластеры
 - Виртуальные машины
-


Литература

- <http://www.clusterresources.com>
 - <http://www.mosix.org>
 - <http://www.openmosix.org>
 - <http://bproc.sourceforge.net/>
 - <http://www.linuxvirtualserver.org/>
-

Кластеры типа Beowulf

- Типа Beowulf
 - Компьютеры широкого использования
 - Распределенный образ операционной системы
 - Централизованная модель
 - Гетерогенность
 - Возможные расширения
 - Общая память
 - Миграция процессов
 - Чекпоинт/рестарт
-

Схема



Узлы кластера

- *рабочие узлы* (worker node)
 - выполнение расчета
 - *хранения данных* (storage node)
 - хранение доступных данных
 - *узлы управления* (management node)
 - программное обеспечение для администрирования системы
 - базы данных системной информации (NIS master, LDAP master)
 - *узлы доступа* (login node)
 - вход пользователей из Интернет
 - *узлы распределения нагрузки* (workload management node)
 - Сервер и планировщик системы управления нагрузкой
 - Коммуникации
 - Сеть быстрого обмена данными
 - Сеть мониторинга
-

Работа узлов в кластере


- Работа кластера как одной системы определяется программным обеспечением
- Узлы кластера должны "доверять" друг другу
 - возможность запускать программы на разных узлах кластера без ввода пароля
 - Файлы данных должны быть доступны всем узлам
- Модель программирования
 - Обмен сообщениями (MPI, PVM)
 - Общая память
 - На многопроцессорных узлах
 - При наличии соответствующей сети (SCI, QSNNet)
 - Комбинированная

Запуск программ на кластере

- Для запуска на любом узле кластера
 - Ssh, rsh
 - Агенты системы распределения нагрузки
 - Запуск параллельных программ
 - Ssh или rsh для запуска соответствующего процесса на удаленной машине
-


Входные узлы

- Входной узел
 - Брандмауэр
 - Маршрутизатор для узлов кластера
 - Кэширующий DNS
 - Запуск программ на рабочих узлах
 - Интерфейс системы мониторинга
- Часто пользователи не имеют прямого доступа ни на какие узлы, кроме входных



Базы данных системной информации


- Узел управления содержит авторитетные копии баз данных системной информации
 - Список пользователей
 - Список групп
- Новая информация добавляется и изменяется только на узле управления
- Остальные узлы
 - Обращаются к базе данных при необходимости
 - Могут содержать реплики главной базы данных
- При любом акте авторизации или аутентификации
 - Обращения идут к к главному серверу
 - Может выполняться кэширование на локальных узлах (NSCD)



Система мониторинга

- Рабочие узлы
 - Агенты сбора информации
 - Узел коллектора (входной или управления)
 - Агрегация и анализ информации
 - Узел управления
 - Система включения-выключения узлов
-

GANGLIA



Система распределения нагрузки

- Задачи
 - Максимально эффективное использование ресурсов кластера
 - Максимальная скорость вычислений
 - Удовлетворение требований пользователей в необходимых ресурсах
 - Память
 - Дисковое место
 - Специальные ресурсы (стример)
-

Повышение эффективности использования ресурсов


- **Пакетный режим**
 - Пользователи указывают необходимые ресурсы
 - Пользователи ставят свои задачи в очередь
 - Система выполняет задачи в очереди в порядке приоритетности
 - **Распределение нагрузки**
 - Запуск программ оптимальным (в плане скорости) образом
 - **Контроль использования ресурсов**
 - При превышении лимитов задача завершается принудительно
-

Реализации систем пакетного режима


- NQS – network queuing system
 - PBS – portable batch system
 - torque
 - LL – load leveler
 - BQS - Batch Queing System
 - CONDOR
 - LSF
-

PBS

- Агент менеджера ресурсов (pbs_mom)
– machine oriented miniserver
 - Сбор информации о загруженности своего узла
 - Запуск программ на своем узле
 - Остановка задач на своем узле
- Сервер (pbs_server)
 - Агрегация информации от агентов
 - Поддержка очередей
 - Запуск задач посредством агентов на заданных серверах
- Планировщик
 - Выдача информации серверу об оптимальном выборе ресурсов для разных задач



Структурная схема PBS



Агент менеджера ресурсов

- Клиент-серверная идеология
 - Может подсоединяться к серверу и планировщику для передачи информации
 - Слушает порт с возможностью подсоединения
- Периодически передает серверу информацию о загруженности и занятых ресурсах
- Выполняет указания сервера и планировщика по запуску и остановке задач

```
813 ?      S   29:34 /usr/local/torque/sbin/pbs_mom
11866 ?    S   0:00 \_ -bash
11867 ?    S   0:01 \_ pbs_demux
11920 ?    S   0:00 \_ /bin/bash -x /var/spool/torque/mom_priv/jobs/8097.cluste.SC
11940 ?    S   0:00 \_ mpirun -np 4 /usr/local/gromacs/i686-pc-linux-gnu/bin/mdrun_mpi
```

Информация о ресурсах

s6

```
state = free
np = 6
ntype = cluster
jobs = 0/8054.cluster.univ.kiev.ua, 1/8054.cluster.univ.kiev.ua, 2/8092.cluster.univ.kiev.ua, 3/8092.cluster.univ.kiev.ua
status = arch=linux,uname=Linux ss20-6.univ.kiev.ua 2.4.29 #4 SMP Sat Mar 12 18:51:26 EET 2005 i686,sessions=11486 11485 13077
13179
13180,nsessions=5,nusers=1,idletime=75517,totmem=3137424kb,availmem=2764512kb,physmem=1032920kb,ncpus=4,loadave=2.81,g
res=sse2:1+old:1+sse:1+ia32:1,netload=4091552988,size=12243388kb:16513960kb,state=free,rectime=1121093394
```

s16

```
state = free
np = 6
ntype = cluster
jobs = 0/8106.cluster.univ.kiev.ua, 1/8105.cluster.univ.kiev.ua
status = arch=linux,uname=Linux ss20-16.univ.kiev.ua 2.6.12 #2 SMP Sat Jun 25 11:53:19 EEST 2005 x86_64,sessions=2057 27304 27314
27315 14563
25193,nsessions=6,nusers=3,idletime=257369,totmem=4153400kb,availmem=3755768kb,physmem=2056928kb,ncpus=4,loadave=1.90,
gres=new:1+ia32e:1+x86_64:1+sse2:1+sse3:1+sse2:1+sse:1+ia32:1,netload=344160256,size=18281492kb:30254032kb,state=free,recti
me=1121093374
```

s17

```
state = free
np = 6
ntype = cluster
jobs = 0/8054.cluster.univ.kiev.ua, 1/8054.cluster.univ.kiev.ua, 2/8092.cluster.univ.kiev.ua, 3/8092.cluster.univ.kiev.ua
status = arch=linux,uname=Linux ss20-17.univ.kiev.ua 2.4.29 #3 SMP Wed Feb 23 12:42:34 EET 2005 i686,sessions=14044 14043 17177
17178,nsessions=4,nusers=1,idletime=80182,totmem=5193984kb,availmem=4895448kb,physmem=1032504kb,ncpus=4,loadave=2.15,g
res=sse2:1+old:1+sse:1+ia32:1,netload=1580948483,size=1097220kb:4128448kb,state=free,rectime=1121093374
```

Сервер

- Организация очередей
 - Агрегация использования ресурсов
 - Очередь (класс)
 - В каждую очередь попадают задачи с определенными требованиями по ресурсам
 - Задачи с одинаковыми требованиями выполняются последовательно
 - Сервер указывает агентам, что запускать
-

Очереди

```
#
# Create and define queue mono_long
#
create queue mono_long
set queue mono_long queue_type = Execution
set queue mono_long Priority = 4
set queue mono_long max_running = 23
set queue mono_long resources_max.nodect = 1
set queue mono_long resources_min.walltime = 36:00:00
set queue mono_long resources_default.walltime = 72:00:00
set queue mono_long max_user_run = 10
set queue mono_long enabled = True
set queue mono_long started = True
#
# Create and define queue stereo_short
#
create queue stereo_short
set queue stereo_short queue_type = Execution
set queue stereo_short Priority = 4
set queue stereo_short resources_max.walltime = 64:00:00
set queue stereo_short resources_min.nodect = 2
set queue stereo_short max_user_run = 4
set queue stereo_short enabled = True
set queue stereo_short started = True
#
# Create and define queue stereo_long
#
```

server: cluster.univ.kiev.ua

Queue	Memory	CPU	Time	Walltime	Node	Run	Que	Lm	State
-----	---	---	---	---	---	---	---	---	---
mono_short	--	--		36:00:00	1	0	0	--	E R
default	--	--		--	--	0	0	--	E R
mono_long	--	--		--	1	4	0	23	E R
stereo_short	--	--		64:00:00	--	0	0	--	E R
stereo_long	--	--		--	--	3	1	--	E R
alien	--	--		--	--	0	0	--	E R
						---	---		
						7	1		

Планировщик

- На основе информации
 - менеджера ресурсов
 - Требований пользователя
 - Ограничений
 - Запланировать выполнение всех задач с максимальной эффективностью
-

Реализации планировщиков

- PBS_SCHEDULER
 - Входит в систему PBS
 - MAUI
 - Самый распространенный кластерный планировщик
 - Организация качества обслуживания
 - Приоритеты
 - Вытеснение
 - Назначение ограничений
-

Сценарий запуска (паспорт задачи)

- Задача может быть запущена на любом узле кластера
- Чтобы все запустилось правильно пользователь должен указать как запускать задачу
 - Имя и путь к программе
 - Необходимые ресурсы
- PBS предоставляет пользователю переменные среды
 - Имена машин на которых были запущены задачи
 - Имена машин и каталог из которых бала запущена задача
 - ...

Пример запуска

■ Сценарий

```
#PBS
cat $PBS_NODEFILE
sleep 20
```

■ Запуск

```
qsub -lnodes=2:ppn=2 tst
8115.cluster.univ.kiev.ua
```

■ Выполнение

```
[saa@cluster pbs]$ qstat
```

Job id	Name	User	Time Use	S	Queue
8054.cluster	dopc_ann_4	yesint	00:01:29	R	stereo_long
8092.cluster	dopc_f2n8_ann	yesint	00:00:55	R	stereo_long
8097.cluster	eEF1A2_n5	kanibolotsky	00:00:01	R	stereo_long
8102.cluster	eEF1A2_n10	kanibolotsky		0	Q stereo_long
8103.cluster	...01_restart-07	platon	47:06:22	R	mono_long
8104.cluster	...02_restart-07	platon	47:30:02	R	mono_long
8105.cluster	...04_restart-06	platon	47:19:13	R	mono_long
8106.cluster	...03_restart-06	platon	22:02:52	R	mono_long
8115.cluster	tst	saa	00:00:00	R	stereo_short

■ Результат

```
s16
s16
s15
s15
```

Особенности кластера типа beowulf

- Преимущества
 - Гетерогенность – не помеха
 - Независимость от программного и аппаратного обеспечения
 - Простота организации
 - Высокая надежность
 - Высокая масштабируемость
 - Низкое соотношение цена/производительность
- Недостатки
 - Статическое распределение нагрузки
 - Необходимость сложных настроек для получения оптимальной производительности

bproc

- Общее пространство процессов для beowulf кластеров (SSI)
- Процессы выполняются на удаленных узлах и могут мигрировать между узлами, хотя видятся как запущенные на входном узле
- Миграция путем полной копии ресурсов (виртуальной памяти, открытых файлов)

Кластер типа MOSIX

- MOSIX – Multicomputer Operating System for Unix
 - Кластер с одной копией операционной системы
 - Динамическая балансировка нагрузки путем миграции процессов с вытеснением
-


Компоненты

- Децентрализованная схема
 - Каждый узел имеет одинаковую структуру и все узлы равноправны
- Каждый узел имеет
 - Информационный агент
 - Передача информации об использовании ресурсов своего узла
 - Прием информации о ресурсах других узлов
 - Агент миграции
 - Принимает запросы от других узлов на миграцию процессов с них
 - Запускает мигрировавшие процессы
 - Планировщик
 - Принимает решение о миграции процессов со своего узла

Концепция домашнего узла

- Каждый процесс остается связанным с той машиной, на которой он был запущен
 - При миграции процесс разбивается на две части
 - Deputy – режим ядра, связанный с домашним узлом
 - Remote – режим ядра и режим задачи, связанный с удаленным узлом
 - При выполнении системного вызова удаленной частью процесса, вызов транслируется на домашний узел по сети
-

Выполнение системного вызова



Особенности

■ Преимущества

- ❑ Эффективен для гетерогенных кластеров
- ❑ Не требует специфических настроек
- ❑ Динамическая масштабируемость
- ❑ Возможность использования существующих ресурсов для создания метакластеров


■ Недостатки

- ❑ Требует однотипного (не сильно отличающегося) аппаратного и программного обеспечения
 - ❑ Не удовлетворяет требованиям стабильности и безопасности
 - ❑ Концепция домашнего узла – ограничивает возможности
-

SSI Linux


- Полнофункциональный кластер с общим образом операционной системы
 - Общее пространство процессов
 - Общая память
 - Общая файловая система
 - Общие средства коммуникации
 - Интегрирует в себе многие другие проекты
-

Структурная схема




Балансирующие кластеры

- Кластер серверов видится как одна машина
- Внутри запросы к общему адресу распределяются между серверами, входящими в кластер



Linux Virtual Server

- NAT
- Direct route
- IP tunnel



Высоконадежные кластеры


- Отказоустойчивость (fault-tolerance)
 - При возникновении сбоев может сам восстановиться
 - Высокая готовность (high availability)
 - При обнаружении ошибки быстро готов к выполнению работы
-

Условия обеспечения высокой надежности

- Обнаружение отказов
 - Избыточность – высокая готовность
 - Запасные компоненты, готовые сразу же включиться в работу
 - Журналирование (транзакции) - отказоустойчивость
 - Сохранение промежуточных действий с возможностью вернуться к последней успешной операции
 - Механизм устранения неисправных компонент
-

Обнаружение отказов


- Keep-alive, hello, heartbeat
 - Периодически отправляемая информация о состоянии каждого узла (компоненты)
- Если сообщения от компоненты не поступают или поступают с неверными параметрами, то фиксируется отказ компоненты



Устранение неисправной компоненты

■ Stomish

- Shoot Other Machine In The Head
- Задача – быстро устранить неисправную машину
- Метод – выключение питания с помощью управляемого выключателя питания
- Исполнитель – одна из машин кластера
 - Временный координатор



Избыточность

- Избыточность данных
 - Зеркалирование – создание полной копии
 - Репликация – восстановление из копии
 - Multipass – обеспечение нескольких путей к данным
 - Избыточность функций
 - Дублирование – несколько серверов, процессов, сетевых адаптеров и др. устройств с одинаковыми функциями
-

Журналирование


- Журналирование данных
 - Перед тем, как записывать данные на постоянное место, они записываются во временное хранилище - журнал
 - После этого данные записываются на постоянное место
 - Транзакции
 - Несколько последовательных операций выполняются как одна атомарная операция
 - Checkpoint/restart
 - Создается копия структур данных процесса
-

CHROX – CHeckPOinting linuX


- Сохранение текущего состояния процесса в дисковый файл
 - Восстановление процессов из файла в точке, где они были записаны
 - Процессы после восстановления продолжают выполняться
-

Схема работы

Резервирование



Восстановление



Пример работы

```
$ cat test.sh
#!/bin/sh
I=1
while true;
do
    echo $I
    I=$((I+1))
    sleep 5
done

$ ./test.sh
1
2
3
█
```

```
$ ps xo pid,cmd|grep test
780 /bin/sh ./test.sh
788 grep test
$ chpoxctl add 780 40 9 /tmp/test.dump
$ kill -40 780
$ ld-chpox /tmp/test.dump
14
15
16
17
18
19
20
21
█
```

Виртуальные машины

- Эмуляция аппаратного обеспечения компьютера с помощью программных средств
 - Создание иллюзии того, что операционная система выполняется на аппаратном обеспечении
-

Примеры виртуальных машин

- Xen – виртуализация ресурсов компьютера
 - Qemu – эмулятор аппаратного обеспечения
 - VMWare – эмулятор аппаратного обеспечения
 - UML – user mode Linux
-

Вопросы
