

*Институт математического моделирования
Российской академии наук*

Балансировка загрузки процессоров

М.В.Якобовский

mail: lira@imamod.ru

web: <http://lira.imamod.ru>

Нижний Новгород

2009

Задачи большого вызова


(Kenneth G. Wilson, Cornell University, 1987)

- Вычислительная газовая динамика:
 - Создание летательных аппаратов, эффективных автомобилей
 - Предсказание погоды, и глобальных климатических изменений
 - Оптимизация нефтедобычи, ...
- Молекулярная динамика:
 - Создание материалов с заданными свойствами
 - Разработка новых лекарственных соединений
 - Сверхпроводимость, Свойства веществ в экстремальных состояниях, ...
- Символьные вычисления
 - Распознавание речи
 - Компьютерное зрение
 - Изучение сложных систем
 - Автономные системы управления
- Квантовая хромодинамика и теория конденсированных сред
- Управляемый термоядерный синтез, Геном человека, ...

Дозвуковая аэродинамическая труба Т-104. ЦАГИ

- Скорость потока **10–120 м/с**
- Диаметр сопла 7 м
- Длина рабочей части 13 м
- Мощность вентилятора **28.4 МВт**

<http://www.tsagi.ru/rus/base/t104>



Суперкомпьютер СКИФ МГУ «ЧЕБЫШЁВ»


- Пиковая производительность 60 TFlop/s
- Мощность комплекса **0.72 МВт**


http://parallel.ru/cluster/skif_msu.html













Суперкомпьютеры

- Не просто составляют конкуренцию натурному эксперименту, но:
 - Необходимы для его проведения
 - Позволяют делать то, что натуральный эксперимент делать не позволяет



Суперкомпьютеры

- Используются неэффективно и далеко не в полной мере
- Необходимы:
 - Вычислительное ядро: адаптация алгоритмов к архитектуре многопроцессорных систем с распределённой памятью
 - Специальное математическое обеспечение: визуализация, генерация сеток, рациональное разбиение на подобласти, динамическая балансировка загрузки процессоров, использование CAD-технологий, использование гетерогенных систем и GRID-технологий
 - Интеграция в единый программный комплекс





НЕВЯЗКОЕ ОБТЕКАНИЕ КУЗОВА АВТОМОБИЛЯ ($M = 0.12$)



СЕТКА: 430 949 УЗЛОВ, 2 430 306 ТЕТРАЭДРОВ

НЕВЯЗКОЕ ОБТЕКАНИЕ КУЗОВА АВТОМОБИЛЯ





Сетка: 209 028 730 узлов, 1 244 316 672 тетраэдра (24 Гб)


МВС: МВС-100К

1. Запуск задачи на 128, 192, 256, 320, 384 и 437 модулях с порождением 2 и 4 параллельных MPI процессов (до 1748 параллельных процессов).

2. Запуск задачи на 437 модулях в рамках гибридной модели параллелизма MPI + OpenMP (3496 параллельных процессов)



Суперкомпьютеры



МСЦ РАН: процессор: Intel(R) Xeon(R) CPU X5365 @ 3.00GHz
ядер на узел: 8
память узла: 4/8 Гб
число узлов: 782 (6256 ядер)
коммуникации: InfiniBand DDR
производительность: 75 TFLOPS


СКИФ МГУ: процессор: Intel(R) Xeon(R) CPU E5472 @ 3.00GHz
ядер на узел: 8
память узла: 8 Гб
число узлов: 630 (5040 ядер)
коммуникации: InfiniBand DDR
производительность: 60 TFLOPS

Акустика

Вычислительные эксперименты по ЗПК




Звукопоглощающие конструкции




Эксперимент 1: Модель 2D и 3D импедансной трубы

2D задача




3D задача




Концентрация сетки около горла резонатора


Размер сетки до 90К узлов



Размер сетки до 1М узлов




Течение в отверстии резонаторной камеры




Эксперимент 2: 2D канал с резонаторами (2/2)

Эффект свиста



Слой смешения



Возмущения плотности



Базовая численная схема (1/2)

2D контрольные объемы



Декартова сетка

Неструктурированная
треугольная сетка

Медианные ячейки







Ячейки на центрах описанных окружностей



3D контрольные объемы

Декартова сетка


Неструктурированная
тетраэдральная сетка



Базовая численная схема


Пространственный шаблон для определения потока между узлами I и J
(сложность для распараллеливания)

2D треугольная сетка



2D шаблон высокого порядка:
Противопоточные треугольники + соседи

3D тетраэдральная сетка



3D шаблон высокого порядка:
Противопоточные тетраэдры + соседи

Канал с 5 резонаторами

Применимость не только суперкомпьютеров,
но и Grid технологий



Возмущения плотности

Уравнения Эйлера, нет погранслоя, $M=0.4$


Производительность вычислений

Две различные параллельные системы использовались для тестов

- 1) Типичный малобюджетный кластер с обычной сетью Ethernet
Узел: 2CPU Intel Xeon 3GHz
Сеть: Ethernet 1Gbit
- 2) “Продвинутый” кластер с высокопроизводительной сетью низкой латентности
Узел: 2CPU AMD Opteron 2.4Hz
Сеть: Myrinet


Эти системы имеют существенно различное отношение производительности процессора и сети

Тестовая задача: Модельная 2D задача – импедансная труба.
Размер сетки 80 000 узлов, схема 5-го порядка



Пример разбиения сетки

Статическая балансировка загрузки



$$G = (V, E), \quad V = \{v_i\}, \quad |V| = n$$


$$R(V) = (V_1, \dots, V_p)$$

$$V = \bigcup_{k=1}^p V_k, \quad V_i \cap V_j = \emptyset, \quad i \neq j$$

$$\min_{R(V)} \left\{ J = \max_{k=1, \dots, p} \sum_{v_i \in V_k} \left(w(v_i) + \alpha \sum_{v_j \notin V_k} w(v_i, v_j) \right) \right\}$$

Критерии декомпозиции графов

- Равномерное распределение суммарного веса узлов/рёбер
- Минимизация максимального веса исходящих из домена ребер
- Минимизация суммарного веса разрезанных ребер
- Минимизация максимальной степени доменов
- Обеспечение связности доменов
- Обеспечение связности множества внутренних узлов доменов



А.Н. Андрианов, А.В. Жохова, Б.Н. Четверушкин

Процессоров	11	31	47	63
New_sort	13.59	5.59	4.38	4.16
METIS	13.61	11.00	11.10	10.56

Чему равно $25/4$?

6.25

$$25/4=$$

~~6.25~~


$$25/4=$$

6 ~~6.25~~ 9


4

$$25/4 = 4 ? 6 ? 9$$

- Разрезать решетку 5 x 5 на 4 части




Декомпозиция сетки из 25 узлов на 4 части



$$25/4 = 4 ? 6 ? 9$$


- Декомпозиция решетки 5 x 5 на 4 домена



- Дисбаланс $9/4=2.25$


$$25/4 = 4 ? 6 ? 9$$

- Декомпозиция решетки 5 x 5 на 2 домена
- Дисбаланс 13/12 : 8%




$$25/4 = 4 ? 6 ? 9$$

- Декомпозиция решетки 5 x 5 на 4 домена
- Дисбаланс 7/6 : 17%



$$25/4 = 4 ? 6 ? 9$$


- Декомпозиция решетки 5 x 5 на 4 домена



- Дисбаланс $9/4=2.25$

$$25/4 = 4 ? 6 ? 9$$

- Декомпозиция решетки 5 x 5 на 4 домена






- ~~• Дисбаланс $9/4=2.25$~~

$$25/4 = 4 ? 6 ? 9$$

- Декомпозиция решетки 5 x 5 на 4 домена




Потери $9/6.25=1.44$



- ~~• Дисбаланс $9/4=2.25$~~

Потери
 $9/7=1.29$

Декомпозиция сетки 25x25 на 7 частей



Разбиение тетраэдральной сетки, содержащей $2 \cdot 10^8$ узлов, на 125 процессорах



- вычисления производились на кластере СКИФ МГУ (1250 4-ядерных процессоров, 60 TFlop/s)

		геометрическая декомпозиция		ParMETIS	
число доменов		80 000		20 000	
время		21 сек.		10 сек.	
число вершин в домене		2612	2613	2 328	10 932
мин.	макс.				
среднее число связей с соседними доменами		14		14	
число некомпактных доменов		229		364	


Фрагмент треугольной сетки из 75790 вершин

результат геометрической
декомпозиции




результат перераспределения
малых блоков вершин




Иерархический алгоритм



Огрубление графа




Локальное уточнение



Kernighan-Lin (KL)
и Fiduccia-Mattheyses (FM)


Связность ядер доменов





$$d(i) = \min_k : \mathbf{A}^k v_i \cap B \neq \emptyset$$

$$T_{k+1} = \mathbf{A}T_k \setminus T_k \setminus T_{k-1}, \quad T_{-1} = \emptyset$$


Инкрементный алгоритм декомпозиции графа




Редуцирование доменов




Инкрементный алгоритм, $Dm=8$




Инкрементный алгоритм, $Dm=25$



Результат локального разбиения сетки из 75790 вершин на 50 доменов на 5 процессорах





Результат сбора плохих групп доменов и их повторного разбиения




Адаптивные сетки

Обтекание профиля NASA0012
($M=0.85$, $Re=10^4$)
под нулевым углом атаки:





Поле продольной скорости



Фрагмент сетки



Равномерная сетка

Слева – ??*круглое*?? пятно примеси



Адаптивная сетка


Слева – *круглое* пятно примеси



Адаптивные декартовы сетки

- Вначале сетка состоит из одной прямоугольной ячейки
- Каждая ячейка может быть **разделена** на четыре ячейки одинакового размера
- Если ячейки когда-то составляли одну ячейку, то они могут быть **объединены** обратно
- Каждая ячейка хранит **величину**, описывающую среднее значение неизвестной функции в пределах ячейки (метод конечных объёмов)

При данных предположениях сетку удобно хранить в виде **четверичного дерева**:





Дополнительные ограничения на размеры ячеек:

- Задан **максимально допустимый** размер ячеек
- Задан **минимально допустимый** размер ячеек
- Размеры соседних ячеек должны различаться **не более, чем в 2 раза**


Сравнение с равномерной сеткой

сеткой

На рисунках показаны результаты решения простейшей задачи переноса на равномерной (слева) и адаптивной (справа) сетках с одинаковым числом ячеек (4096 штук). Скорость переноса направлена под углом 45° к линиям сетки; начальное условие показано пунктиром



Адаптивная сетка





Решение двумерной задачи фильтрации нефтеводяной смеси в области с неоднородной проницаемостью

В юго-западном углу находится скважина, нагнетающая воду, в северо-восточном углу — добывающая скважина.

5-ти точечная схема

Поле проницаемости с разбросом значений на 4 порядка).





Решение двумерной задачи фильтрации нефтеводяной смеси в области с неоднородной проницаемостью

В юго-западном углу находится скважина, нагнетающая воду, в северо-восточном углу — добывающая скважина.

5-ти точечная схема


Поле проницаемости с разбросом значений на 4 порядка).




Динамическая балансировка загрузки

- Перераспределение вычислительных узлов между процессорами необходимо:
 - При изменении конфигурации сетки
 - При изменении вычислительной сложности обработки узлов
 - При изменении эффективной производительности процессоров

Декомпозиция пакетом Metis







Нумерация с помощью кривой Гильберта

Формируется простой рекурсивной процедурой

Локальное изменение сетки приводит к локальному изменению кривой

Декомпозиция с помощью кривой Гильберта





Стратегии балансировки загрузки

W_i^j - вычислительная нагрузка,
ассоциированная с узлом сетки i на

Статическая


Динамическая
диффузная

- $W_i^j = W_i^j$ – не зависит от времени
- $W_i^j \approx W_i^{j-1}$ – меняется медленно
- $W_i^j \neq W_i^{j-1}$ – меняется значительно и прогнозируемо

Динамическая


?

Моделирование задач горения на многопроцессорных системах



Methane combustion

CH_4 NO NO_2 NO_2 CH_3 CO CO_2 T



Моделирование задач горения

$$\frac{\partial \mathbf{U}}{\partial t} + A\mathbf{U} = f, \quad \mathbf{U} = (\rho, \rho y^{(i)}, \rho u, \rho v, E)^T \quad f = (0, \omega_i, 0, 0, 0)^T$$

Здесь A оператор, ρ - плотность,
 $y^{(i)}$ – массовые доли i -х компонент,
 u, v - скорости,
 p - давление, E – полная энергия,
 ω_i – скорости образования компонент.

I. Блок Газовой динамики (GD):

$$\frac{\partial \mathbf{U}}{\partial t} + A\mathbf{U} = 0$$


$$\frac{\mathbf{U}^{j+1} - \mathbf{U}^j}{\Delta t} + \frac{1}{2}(A\mathbf{U}^{j+1} + A\mathbf{U}^j) = 0.$$

II. Блок химической кинетики (CHEM):


$$\frac{d\mathbf{U}}{dt} = f, \quad f = (0, \omega_i, 0, 0, 0)^T$$





Блок схема алгоритма



Распределение времени счета



Структура и возможности алгоритма



Состояния обрабатывающего процесса

- **занят** - если установлен соответствующий флаг. Этот флаг устанавливается перед передачей обрабатывающему процессу необработанной точки (неважно локальной или внешней) и сбрасывается после того, как точка уже обработана и управляющий процесс получил от обрабатывающего процесса результат;
- **свободен** - если не занят, т.е. готов к получению очередной свободной точки.

Управляющий процесс

- **1. если**
 - есть необработанные точки (неважно локальные или внешние) **и**
 - обрабатывающий процесс свободен,
- **то**

установить **флаг обрабатываемой точки**, одна из необработанных точек передается на обработку обрабатывающему процессу.

Управляющий процесс

- **2. если**

- нет локальных необработанных точек ***и***

- нет внешних точек ***и***

- нет обрабатываемых точек ***и***

- ***флаг запроса на получение необработанных точек*** не установлен ***и***

- есть процессоры, которые еще не ответили, что не могут предоставить точки для обработки (соответствующий флаг ***флаг запрета обменов*** не установлен),

- ***то***

- послать запрос на получение необработанных точек одному из таких процессоров.

- установить ***флаг запроса на получение необработанных точек***

Управляющий процесс

- **Иначе (если не 2)**
- **3. если**
 - все переданные точки получены обратно обработанными **и**
 - от всех процессоров получено сообщение о том, что точки для обработки предоставлены быть не могут **и**
 - всем процессорам послано сообщение о том, что точки для обработки предоставлены быть не могут,
то
завершение работы


Управляющий процесс

- 4. получить очередное сообщение от любого процессора или от своего обрабатывающего процесса.
- 5. обработать полученное сообщение
- 6. перейти к началу цикла (п. 1)

Окончание при выполнении всех условий:

- нет локальных необработанных точек
- нет внешних точек
- нет обрабатываемых точек
- всем процессорам был послан запрос на получение необработанных точек
- всем процессорам было послано сообщение о том, что необработанные точки предоставлены быть не могут
- от всех процессоров получено сообщение о том, что необработанные точки предоставлены быть не могут
- все локальные точки обработаны и получены

Кластеры и эффективность



32 processors

12 processors






Схема взаимодействия процессов



Выводы

- Балансировка загрузки процессоров – ключевой этап обеспечения высокой эффективности использования многопроцессорной системы.
- С ростом числа процессоров возрастает актуальность использования динамической балансировки загрузки