

Московский государственный университет им. М.В. Ломоносова



Введение в методы параллельных вычислений

Разработчик:
А.В. Старченко, д.ф.-м.н., профессор
E-mail: starch@math.tsu.ru
Томский государственный университет

Направление 010300.68
«Фундаментальная информатика и информационные технологии»

Проект комиссии Президента по модернизации и техническому развитию экономики России
«Создание системы подготовки высококвалифицированных кадров в области суперкомпьютерных технологий и специализированного программного обеспечения»

Суперкомпьютерный консорциум университетов России



Разработка курса выполнена в рамках Проекта комиссии Президента РФ по модернизации и техническому развитию экономики России «Создание системы подготовки высококвалифицированных кадров в области суперкомпьютерных технологий и специализированного программного обеспечения»

Применение потенциала суперкомпьютерных технологий (СКТ) как значимой составляющей инновационного развития страны является задачей государственной важности, относится к приоритетному направлению и находится под постоянным контролем Президента и Правительства России. Одним из сдерживающих факторов развития страны в этом направлении является острая нехватка высококвалифицированных кадров в области СКТ, поскольку подготовка таких специалистов сейчас отсутствует как элемент системы высшего профессионального образования.

Стратегической целью проекта является создание национальной системы подготовки высококвалифицированных кадров в области суперкомпьютерных технологий и специализированного программного обеспечения.

[http://hpc-education.ru.](http://hpc-education.ru)

© Московский государственный университет © Томский государственный университет Старченко А.В.

Суперкомпьютерный консорциум университетов России



Содержание курса

- Введение
- Рекуррентные формулы
- Параллельные вычисления определенных и кратных интегралов
- Умножение матрицы на вектор. Умножение матриц
- Прямые методы решения систем линейных уравнений на многопроцессорных системах Организация межпроцессорных обменов
- Трехдиагональные системы. Параллельная реализация прямых методов решения систем линейных уравнений
- Параллельная реализация итерационных методов решения СЛАУ
- Параллельная реализация быстрого преобразования Фурье

© Московский государственный университет © Томский государственный университет Старченко А.В.

3

Суперкомпьютерный консорциум университетов России



Содержание лекции

- Вычисление скалярного произведения векторов на p -процессорной системе
- Вычисление произведения матрицы на вектор на p -процессорной системе
 - Общая схема построения параллельного алгоритма
 - Достижение максимально возможного быстродействия ($p=n^2$)
 - Использование параллелизма среднего уровня ($n < p < n^2$)
 - Конвейерная схема
 - Использование ограниченного набора процессорных элементов ($p \ll n$)
- Умножение матриц
 - Общая схема построения параллельного алгоритма
 - Блочные алгоритмы умножения матриц: простой блочный алгоритм, алгоритм Кэннона, алгоритм Фокса
- Заключение

© Московский государственный университет © Томский государственный университет Старченко А.В.

4

Суперкомпьютерный консорциум университетов России



Вычисление скалярного произведения векторов

- Рассмотрим базовые алгоритмы линейной алгебры: вычисление скалярного произведения, матрично-векторное умножение и умножение матриц
- Пусть $x, y \in \mathbb{R}^n$ и требуется найти значение скалярного произведения векторов

$$(x, y) = \sum_{i=1}^n x_i y_i$$

- Алгоритм требует n умножений и $n-1$ сложений. Для простоты выкладок время выполнения последовательного алгоритма можно оценить как

$$T_1 = (t_{mult} + t_{add}) \cdot n$$

© Московский государственный университет © Томский государственный университет Старченко А.В.

5

Суперкомпьютерный консорциум университетов России



Вычисление скалярного произведения

- Следуя общей методологии построения алгоритмов для параллельных вычислений:
 - **Декомпозиция.** Разобьем задачу на мелкозернистые подзадачи – i -ая подзадача запоминает x_i и y_i и вычисляет произведение $x_i y_i$,
 - **Проектирование коммуникаций.** Коммуникации между подзадачами ($\langle + \rangle$) устанавливаются таким образом, чтобы обеспечить суммирование полученных произведений.

$$(x_1 y_1) + (x_2 y_2) + (x_3 y_3) + (x_4 y_4) + (x_5 y_5) + (x_6 y_6) + (x_7 y_7) + (x_8 y_8)$$

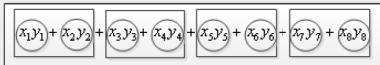
© Московский государственный университет © Томский государственный университет Старченко А.В.

6



Вычисление скалярного произведения

- Укрупнение** подзадач производится путем объединения p/p (p - предполагаемое число процессорных элементов) блоков мелкозернистых подзадач с сохранением коммуникаций между укрупненными блоками
- Планирование вычислений.** Каждый блок назначается на выполнение одному процессорному элементу



Время на вычисление скалярного произведения без учета межпроцессорной передачи данных можно оценить как

$$T_p \approx (t_{mult} + t_{add}) \cdot \frac{n}{p} + t_{add} \cdot \log_2 p$$



Умножение матрицы на вектор

- При умножении квадратной матрицы $A \in \mathbb{R}^{n \times n}$ на вектор $x \in \mathbb{R}^n$ компоненты вектора-результата вычисляются по формуле

$$y_i = \sum_{j=1}^n a_{ij} \cdot x_j; 1 \leq i \leq n; T_1 \approx (t_{mult} + t_{add}) \cdot n^2$$
- При выборе подходов распараллеливания этих формул можно заметить:
 - Вычисление каждого y_i осуществляется независимо и одновременно и может быть выполнено параллельно
 - Умножение каждой строки на вектор включает независимые операции поэлементного умножения, которые могут быть выполнены параллельно
 - Суммирование может осуществляться по алгоритму сдавливания



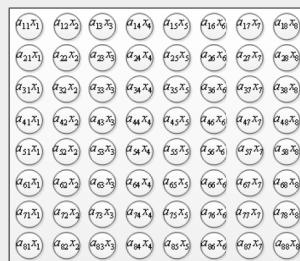
Построение алгоритма для параллельных вычислений

Декомпозиция.

Задачу разбиваем на мелкие задачи, каждая суть

вычисление произведения $a_{ij} \cdot x_j; i, j = 1, \dots, n$.

Всего таких подзадач будет n^2 . Каждая подзадача (i,j) должна иметь информацию о коэффициенте матрицы a_{ij} и компоненте вектора x_j



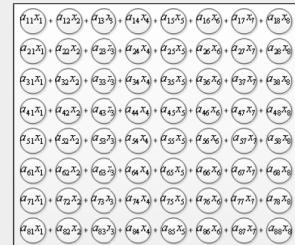
Построение алгоритма для параллельных вычислений

Проектирование коммуникаций.

Для получения значения компоненты вектора y

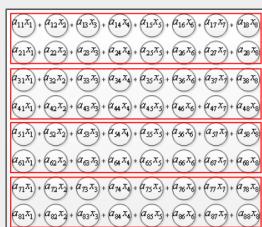
с использованием каскадной схемы суммирования необходимо организовать коммуникации между подзадачами

$(i,1), (i,2), \dots, (i,n)$

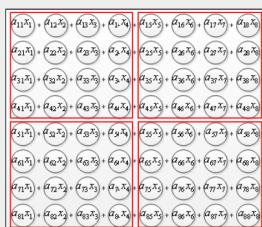


Построение алгоритма для параллельных вычислений

Укрупнение. Поводится на основе одномерной или двумерной стратегии объединения мелкозернистых подзадач.



$n = 8 \ p = 4$



$n = 8 \ p = 4$



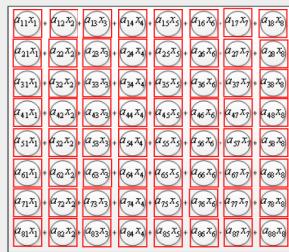
Достижение максимально возможного быстродействия ($p=n^2$)

- В этом случае алгоритм можно разбить на подзадачи, в каждой из которых запоминаются значения элемента матрицы a_{ij} и компоненты вектора x_j , рассчитывается их произведение.
- Коммуникации между подзадачами проектируются таким образом, чтобы организовать по каскадной схеме суммирование соответствующих произведений для вычисления отдельной компоненты вектора y_i .
- Оценим время и ускорение:

$$S_p = \frac{T_1}{T_p} \approx \frac{(t_{mult} + t_{add}) \cdot n^2}{t_{mult} + t_{add} \cdot \log_2 n} \approx \frac{4p}{2 + \log_2 p}$$

Достижение максимально возможного быстродействия ($p=n^2$)

- Для этого случая наиболее подходящими будут топологии, в которых обеспечивается быстрая передача данных в каскадной схеме суммирования: полный граф или гиперкуб.
- Другие топологии приводят к возрастанию коммуникационных затрат из-за удлинения маршрутов передачи данных.



Достижение максимально возможного быстродействия ($p=n^2$)

- Умножение матрицы на вектор на систолическом массиве процессоров ($p=n^2$).
- В таком массиве процессорные элементы находятся в узлах регулярной решетки, в которой роль ребер играют межпроцессорные элементы.
- Все процессоры управляются общим тактовым генератором. В каждом цикле работы любой процессорный элемент (ПЭ) получает данные от соседних ПЭ, выполняет одну команду и передает данные соседям.

Достижение максимально возможного быстродействия ($p=n^2$)

- Систолический алгоритм:
- Элементы матрицы A распределяются по ПЭ так, что элементы j -ой строки матрицы сдвигаются циклически влево на $j-1$ позицию ($n-1$ одиночный сдвиг).

$$A^{(l)} = \begin{pmatrix} a_{11} & a_{12} & \dots & \dots & a_{1n} \\ a_{21} & a_{23} & \dots & \dots & a_{21} \\ a_{33} & a_{34} & \dots & \dots & a_{32} \\ \dots & \dots & \dots & \dots & \dots \\ a_{nn} & a_{n1} & \dots & \dots & a_{n,n-1} \end{pmatrix}$$

Достижение максимально возможного быстродействия ($p=n^2$)

- На основе вектора x создается матрица X такая, что каждый последующий столбец, начиная со второго, получается циклическим сдвигом предыдущего столбца на одну позицию вверх.

$$X = \begin{pmatrix} x_1 & x_2 & \dots & \dots & x_n \\ x_2 & x_3 & \dots & \dots & x_1 \\ x_3 & x_4 & \dots & \dots & x_2 \\ \dots & \dots & \dots & \dots & \dots \\ x_n & x_1 & \dots & \dots & x_{n-1} \end{pmatrix}$$

Достижение максимально возможного быстродействия ($p=n^2$)

- Инициализация:

a_{11}, x_1, y_1	a_{12}, x_2, y_1	a_{13}, x_3, y_1
--------------------	--------------------	--------------------

a_{22}, x_2, y_2	a_{23}, x_3, y_2	a_{21}, x_1, y_2
--------------------	--------------------	--------------------

a_{33}, x_3, y_3	a_{31}, x_1, y_3	a_{32}, x_2, y_3
--------------------	--------------------	--------------------
- Каждый процессор производит умножение пары чисел и записывает результат в y_i , передает a_{ij} левому соседу в решетке, а x_j – верхнему. На следующем цикле данные принимаются от соседних процессорных элементов, снова выполняется умножение пары чисел, суммирование его с y_i и передача данных по ребрам решетки.

Достижение максимально возможного быстродействия ($p=n^2$)

- После окончания алгоритма на каждом ПЭ получается компонента вектора y . В данном алгоритме не используется каскадная схема суммирования.
- Сравнивая показатели эффективности рассмотренных алгоритмов для $p=n^2$ можно отметить более низкую производительность алгоритма на систолическом массиве процессоров.

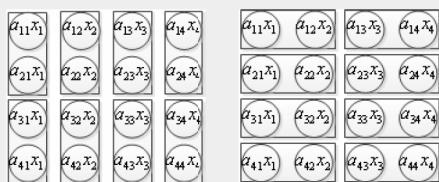
$$S_p = \frac{T_1}{T_p} \approx \frac{(t_{mult} + t_{add}) n^2}{(t_{mult} + t_{add}) n} = n = \sqrt{p};$$

- Наиболее подходящей топологией для вычисления произведения матрицы на вектор на систолическом массиве процессоров является тор или полный граф.



Использование параллелизма среднего уровня ($n < p < n^2$)

- Пусть $p=k \cdot n$ ($1 < k < n$). В этом случае декомпозиция задачи может быть осуществлена двумя способами:
 - либо с последующим применением обычной каскадной схемы суммирования,
 - либо с использованием модифицированной каскадной схемы.



Использование параллелизма среднего уровня ($n < p < n^2$)

- Сравним две схемы декомпозиции (1) и (2), получим:

$$T_p^{(1)} \approx t_{mult} \frac{n^2}{p} + t_{add} \frac{n^2}{p} \log_2 n;$$

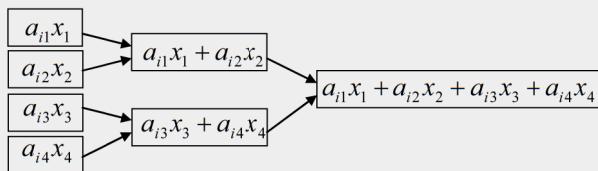
$$T_p^{(2)} \approx (t_{add} + t_{mult}) \frac{n^2}{p} + t_{add} \log_2 \left(\frac{p}{n} \right);$$

- Второй вариант более предпочтителен, например:
 - при $k = n / 2$: $T_p^{(1)} \approx 2t_{mult} + 2t_{add} \log_2 n$;
 - $T_p^{(2)} \approx 2t_{mult} + t_{add} (1 + \log_2 n)$;



Использование параллелизма среднего уровня ($n < p < n^2$)

- При $p=2 \cdot n$ ($k=2$) можно организовать конвейерное умножение матрицы на вектор
- Множество всех $2 \cdot n$ процессорных элементов разбивается на непересекающиеся группы $Q_0, Q_1, \dots, Q_{\log_2 n}$, в каждой из которых $n/2^i$ ($i=0, \dots, \log_2 n$) ПЭ.



Использование параллелизма среднего уровня ($n < p < n^2$)

- Группа Q_0 , объединяющая n процессорных элементов, используется для реализации позлементного умножения i -ой строки матрицы A на вектор x .
- На каждом такте работы конвейера следующая строка матрицы поступает на процессоры группы Q_0 . Следует отметить, что в один момент времени конвейер обрабатывает $\log_2 n + 1$ строк матрицы A .
- При конвейерной реализации умножения матрицы на вектор временные затраты выше.
- Преимущества: меньшее количество пересылок данных между процессорами и возможность получения части результатов до окончания всего вычислительного процесса.
- Топология – двоичное дерево.



Использование ограниченного набора процессоров ($p < n$)

- На каждой из имеющихся процессорных элементов пересыпается вектор x и n/p ($n \bmod p = 0$) строк матрицы A .
- Выполнение операции умножения строк матрицы на вектор выполняется при помощи обычного последовательного алгоритма.
- С математической точки зрения этот алгоритм эквивалентен умножению в блочной форме:

$$y = Ax = \begin{bmatrix} A_1 \\ \dots \\ A_p \end{bmatrix} x = \begin{bmatrix} A_1 x \\ \dots \\ A_p x \end{bmatrix}; \quad T_p \approx (t_{mult} + t_{add}) \frac{n^2}{p}.$$

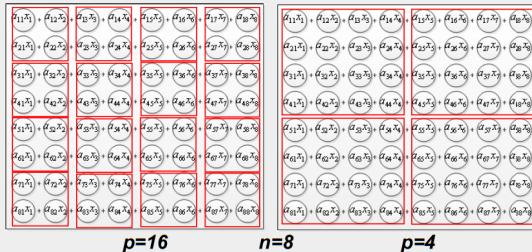
Использование ограниченного набора процессоров ($p < n$)

- При принятом распределении данных по процессорам вычисления произведений осуществляются с максимальным параллелизмом.
- Аналогичные соображения применимы к разбиению матрицы A на группы столбцов.
- Необходимо следить за обеспечением равномерной загрузки процессорных элементов при $n \bmod p \neq 0$.
- Топология – звезда: управляющий ПЭ обеспечивает загрузку вычислительных узлов исходными данными и собирает результаты проведенных вычислений.



Использование ограниченного набора процессоров ($p \ll n$)

- Рассмотрим двумерное укрупнение мелкозернистых подзадач ($p=s^2$ и $n \bmod s=0$). На каждом ПЭ размещается n^2/p элементов матрицы A и n/s компонентов вектора x .



© Московский государственный университет © Томский государственный университет Старченко А.В.

25



Использование ограниченного набора процессоров ($p \ll n$)

- Каждый ПЭ локально выполняет n^2/p умножений и n^2/p сложений полученных произведений.
- Затем по алгоритму сдавливания осуществляется суммирование n/s результатов с ПЭ, расположенных в одном ряду, для определения n/s компонентов вектора y .
- При двумерном укрупнении ускорение параллельного алгоритма несколько ниже, чем при одномерном, что обусловлено использованием алгоритма сдавливания.
- Затраты на инициализацию обоих алгоритмов примерно одинаковы.

© Московский государственный университет © Томский государственный университет Старченко А.В.

26



Умножение матриц

- Задача матричного умножения требует для своего решения выполнения большого количества арифметических операций.
- Пусть A, B, C – квадратные матрицы $n \times n$, $C = AB$. Тогда компоненты матрицы C рассчитываются по следующей формуле $c_{ij} = \sum_{k=1}^n a_{ik} \cdot b_{kj}; i, j = 1, \dots, n$.
- Видно, что для вычисления одного элемента матрицы C требуется n умножений и n сложений. Тогда

$$T_1 \approx (t_{\text{multi}} + t_{\text{add}})n^3.$$

© Московский государственный университет © Томский государственный университет Старченко А.В.

27



Умножение матриц

- Произведение матриц может рассматриваться как n^2 независимых скалярных произведений, либо как n независимых произведений матрицы на вектор. В каждом случае используются различные алгоритмы.
- Производительность умножения матриц может быть улучшена путем изменения порядка циклов $i-j-k$.
- Повышение быстродействия умножения матриц за счет эффективного использования кэш-памяти можно обеспечить с использованием блочного представления матриц.
- Процедура параллельного умножения матриц легко может быть построена на основе полученных выше алгоритмов скалярного умножения векторов или матриочно-векторного умножения для многопроцессорных систем с распределенной памятью.

© Московский государственный университет © Томский государственный университет Старченко А.В.

28



Умножение матриц (общий подход)

- Декомпозиция. На основе проведенного выше анализа выберем в качестве части проблемы (подзадачи) вычисление произведения $a_{ik} \cdot b_{kj}$. Количество таких подзадач равно n^3 , и их можно представить в виде трехмерного массива. Данные, необходимые для вычисления произведения, определяются компонентами матриц a_{ik} и b_{kj} .
- Проектирование коммуникаций. Для вычисления значения элемента матрицы c_{ij} требуется обеспечение коммуникаций между подзадачами, в которых производится расчет произведений $a_{ik} \cdot b_{kj}$, ($k=1, \dots, n$), для последующего суммирования произведений.

© Московский государственный университет © Томский государственный университет Старченко А.В.

29



Умножение матриц (общий подход)

- Укрупнение. Для имеющихся мелкозернистых подзадач могут быть выбраны следующие естественные стратегии их объединения в p ($p \ll n^3$) подзадач:
 - одномерное укрупнение по строкам.
 - одномерное укрупнение по столбцам.
 - двумерное укрупнение. Здесь реализуется алгоритм, основанный на блочном представлении матриц.
 - трехмерное укрупнение.
- Планирование вычислений. На этом этапе разработки параллельного алгоритма необходимо определить, где, на каких процессорных элементах будут выполняться укрупненные подзадачи.

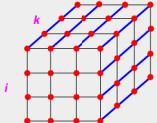
© Московский государственный университет © Томский государственный университет Старченко А.В.

30

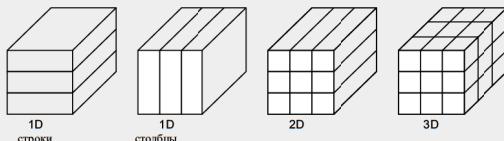


Умножение матриц (общий подход)

- Коммуникации между подзадачами



- Стратегии укрупнения мелкозернистых подзадач



Умножение матриц

- Умножение матриц фиксированного размера за меньшее время можно обработать с использованием 3D-декомпозиции, поскольку для вычислений привлекается большее количество процессорных элементов.

$$T_p \approx (t_{mult} + t_{add}) \cdot n^3 / p;$$

$$S_p \approx \frac{(t_{mult} + t_{add}) \cdot n^3}{(t_{mult} + t_{add}) \cdot n^3 / p} = p;$$

- Алгоритмы, рассмотренные выше, требуют значительных ресурсов памяти многопроцессорной вычислительной системы для хранения блоков матриц.



Простой блочный алгоритм

- Матрица A распределяется по процессорам блоками, содержащими $(n/p)xn$ элементов, B – $nx(n/p)$ элементов.
- Проводится матричное умножение соответствующих блоков, и в результате определяются блоки матрицы C размером $(n/p)x(n/p)$, стоящие на главной диагонали.
- На каждой следующей итерации производится обмен блоками матрицы A между ПЭ циклическим сдвигом по уменьшению номера процессора (или увеличению), вычисления произведения блочных матриц.
- После p итераций расчет матрицы C заканчивается.
- Такой способ параллельного умножения матриц может быть использован при одномерном укрупнении подзадач.



Простой блочный алгоритм

- Этап 1

A_1	x	$B_1 B_2 B_3$	=	$C_{11} C_{12} C_{13}$
A_2				$C_{21} C_{22} C_{23}$
A_3				$C_{31} C_{32} C_{33}$

- Этап 2

A_3	x	$B_1 B_2 B_3$	=	$C_{11} C_{12} C_{13}$
A_1				$C_{21} C_{22} C_{23}$
A_2				$C_{31} C_{32} C_{33}$

- Этап 3

A_2	x	$B_1 B_2 B_3$	=	$C_{11} C_{12} C_{13}$
A_3				$C_{21} C_{22} C_{23}$
A_1				$C_{31} C_{32} C_{33}$

- Объем памяти для 1ПЭ – $3n^2/p$ чисел; суммарный объем пересылаемых данных – n^2 чисел



Алгоритм Кэннона

- Имеется процессорная 2D решетка из $p=s^2$ процессорных элементов ПЭ i,j , $i,j=1,\dots,s$, в которой первый и последний узлы как в ряду процессорной решетки, так и в ее столбце имеют прямое соединение.
- Матрицы A и B делятся на $p=s^2$ блоков согласованных размеров – $A_{ij}, B_{ij}; i,j=1,\dots,s$. На каждый ПЭ i,j рассылаются соответствующие блоки $A_{i,j+i-1}, B_{i+j-1,j}$. ПЭ i,j будет рассчитывать C_{ij} .
- Затем на каждой итерации:
 - Вычисляется произведение блоков.
 - ПЭ i,j отправляет имеющийся блок A на ПЭ $i,j-1$, B – на ПЭ $i-1,j$.
- После выполнения s итераций на каждом ПЭ i,j получается блок C_{ij} .



Алгоритм Кэннона

- Этап 1

$A_{11} A_{12} A_{13}$	x	$B_{11} B_{22} B_{33}$	=	$C_{11} C_{12} C_{13}$
$A_{21} A_{22} A_{23}$		$B_{21} B_{32} B_{13}$		$C_{21} C_{22} C_{23}$
$A_{31} A_{32} A_{33}$		$B_{31} B_{12} B_{23}$		$C_{31} C_{32} C_{33}$

- Этап 2

$A_{12} A_{13} A_{11}$	x	$B_{21} B_{32} B_{13}$	=	$C_{12} C_{13} C_{11}$
$A_{23} A_{21} A_{22}$		$B_{31} B_{12} B_{23}$		$C_{23} C_{21} C_{22}$
$A_{31} A_{32} A_{33}$		$B_{11} B_{22} B_{33}$		$C_{31} C_{32} C_{33}$

- Этап 3

$A_{13} A_{11} A_{12}$	x	$B_{31} B_{12} B_{23}$	=	$C_{13} C_{11} C_{12}$
$A_{21} A_{22} A_{23}$		$B_{11} B_{22} B_{33}$		$C_{21} C_{22} C_{23}$
$A_{32} A_{33} A_{31}$		$B_{21} B_{32} B_{13}$		$C_{32} C_{33} C_{31}$

- Объем памяти для 1ПЭ – $3n^2/p$ чисел; суммарный объем пересылаемых данных – $2n^2/s$ чисел



Алгоритм Фокса

- Имеется процессорная 2D решетка из $p=s^2$ процессорных элементов ПЭ ij , $i,j=1,\dots,s$, в которой первый и последний узлы как в ряду процессорной решетки, так и в ее столбце имеют прямое соединение.
- Матрицы A и B делятся на $p=s^2$ блоков согласованных размеров – A_{ij}, B_{ij} ; $i,j=1,\dots,s$. На каждый ПЭ ij рассылаются соответствующие блоки A_{ij}, B_{ij} . ПЭ ij будет рассчитывать C_{ij} .
- Затем на каждой итерации $I=0,\dots,s-1$:
 - Для каждого i вычисляем $m=(i+I-1) \bmod s + 1$ и блок A_{im} пересыпается на все ПЭ ряда i .
 - Вычисляется произведение блоков, а результат добавляется к блоку C_{ij} .
 - ПЭ ij отправляет имеющийся блок B на ПЭ $i-1,j$.
- После выполнения s итераций на каждом ПЭ ij получается блок C_{ij} .



Алгоритм Фокса

- Этап 1

$$\begin{array}{ccc|c} A_{11} & A_{12} & A_{13} & | & C_{11} \\ A_{21} & A_{22} & A_{23} & \times & C_{21} \\ A_{31} & A_{32} & A_{33} & | & C_{31} \end{array} = \begin{array}{c} C_{11} \\ C_{21} \\ C_{31} \end{array}$$

- Этап 2

$$\begin{array}{ccc|c} A_{12} & A_{12} & A_{12} & | & C_{12} \\ A_{22} & A_{23} & A_{23} & \times & C_{22} \\ A_{31} & A_{31} & A_{31} & | & C_{32} \end{array} = \begin{array}{c} C_{12} \\ C_{22} \\ C_{32} \end{array}$$

- Этап 3

$$\begin{array}{ccc|c} A_{13} & A_{13} & A_{13} & | & C_{13} \\ A_{21} & A_{21} & A_{21} & \times & C_{23} \\ A_{32} & A_{32} & A_{32} & | & C_{33} \end{array} = \begin{array}{c} C_{13} \\ C_{23} \\ C_{33} \end{array}$$

- Объем памяти для 1ПЭ – $4n^2/p$ чисел, суммарный объем пересылаемых данных – $2n^2/s$ чисел



Блочные алгоритмы умножения

- Блочное представление матриц в рассмотренных выше алгоритмах умножения матриц приводит к некоторому повышению объема пересылаемых между процессорными элементами данных.
- Объем пересылаемых данных может быть уменьшен, если использовать строковое для A и столбцовое для B блочное распределение данных по процессорным элементам.
- Блочное представление матриц при параллельном вычислении матричных произведений имеет ряд преимуществ:
 - пересылка данных является распределенной во времени, что позволяет совмещать вычисления и передачу данных;
 - блочная структура может быть использована при решении слабо заполненных СЛАУ.



Заключение

- Рассмотрены базовые алгоритмы линейной алгебры: вычисление скалярного произведения векторов, произведения матрицы на вектор, умножения матриц и способы их распараллеливания на p -процессорной системе с распределенной памятью.
- Для параллельных алгоритмов умножения матрицы на вектор проведено исследование выбора оптимальной топологии p -процессорной системы от числа имеющихся процессорных элементов.
- Для алгоритмов умножения матриц наряду со способами повышения быстродействия вычислительного процесса рассмотрены блочные алгоритмы, позволяющие за счет использования параллелизма увеличить размер решаемой задачи.



Вопросы для обсуждения

- Опишите как с использованием общей схемы построения параллельных алгоритмов получить параллельную программу скалярного умножения векторов.
- Перечислите возможные подходы распараллеливания матриочно-векторного умножения.
- Дайте сравнительный анализ достоинств и недостатков одномерного и двумерного укрупнения при построении параллельного алгоритма умножения матрицы на вектор.
- Опишите параллельный алгоритм матриочно-векторного умножения при максимально необходимом для решения этой задачи числе процессоров.
- Чем объяснить преимущество топологии «полный граф» по сравнению с топологией «линейка» для случая $p=n^2$?
- Какой алгоритм суммирования используется при умножении матриц в систолическом массиве процессоров и какая топология является наиболее подходящей в этом случае?
- Опишите как работает конвейерная схема умножения матрицы на вектор при $p=2n$.
- Оцените время работы параллельного алгоритма конвейерной схемы умножения матрицы на вектор при $p=2n$.



Вопросы для обсуждения

- В чем заключается преимущество конвейерного способа решения задачи?
- Какие способы декомпозиции задачи матрично-векторного умножения возможны при ограниченном числе используемых процессоров? Дайте сравнительный анализ.
- Какая топологическая структура наиболее подходит для параллельного матрично-векторного умножения возможны при ограниченном числе используемых процессоров?
- Как обеспечить баланс загрузки процессоров при $n \bmod p \neq 0$?
- Какие способы повышения производительности умножения матриц известны?
- Какие способы декомпозиции задачи матричного умножения возможны?
- Можно ли рассматривать параллельные вычисления не с точки зрения быстродействия получения результата, а как средство для решения сверхбольших задач, которые не помещаются в память обычного компьютера?
- Какие блочные алгоритмы умножения матриц известны? Преимущества и недостатки.
- Как можно сократить затраты на пересылку данных в алгоритме Фокса?



Темы заданий для самостоятельной работы

- Организация параллельных вычислений произведения матрицы на вектор при $p=n$.
- Написать MPI-программу умножения матрицы на вектор для $p=n^2$.
- Написать MPI-программу умножения матрицы на вектор для конвейерной схемы.
- Написать MPI-программу умножения матриц с помощью блочного алгоритма.



Основная литература

1. Гергель В.П. Теория и практика параллельных вычислений. – М.: Интернет-Университет Информационных технологий; БИНОМ. Лаборатория знаний, 2007.
2. Гергель В.П., Стронгин Р.Г. Основы параллельных вычислений для многопроцессорных вычислительных систем. – Нижний Новгород: Изд-во ННГУ, 2001.
3. Орtega Дж. Введение в параллельные и векторные методы решения линейных систем. – М.:Мир, 1991.
4. Деммель Дж. Вычислительная линейная алгебра. – М.:Мир, 2001.
5. Высокопроизводительные вычисления на кластерах. – Томск: Изд-во Том. ун-та, 2008.



Следующая тема

- Введение
- Рекуррентные формулы
- Параллельные вычисления определенных и кратных интегралов
- Умножение матрицы на вектор. Умножение матриц
- Прямые методы решения систем линейных уравнений на многопроцессорных системах Организация межпроцессорных обменов
- Трехдиагональные системы. Параллельная реализация прямых методов решения систем линейных уравнений
- Параллельная реализация итерационных методов решения СЛАУ
- Параллельная реализация быстрого преобразования Фурье