


НИЖЕГОРОДСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ

им. Н.И. Лобачевского

- Национальный исследовательский университет -

Нижегородский государственный университет им. Н.И. Лобачевского

– Национальный исследовательский университет –

Параллельное программирование с использованием OpenMP

Гергель В.П.

д.т.н, проф., декан факультета ВМК,
руководитель Центра
суперкомпьютерных технологий ННГУ

ОСНОВЫ ПОДХОДА

Технология OpenMP для систем с общей памятью

- Технология OpenMP задумана как стандарт параллельного программирования для многопроцессорных систем с общей памятью (SMP, ccNUMA, …).

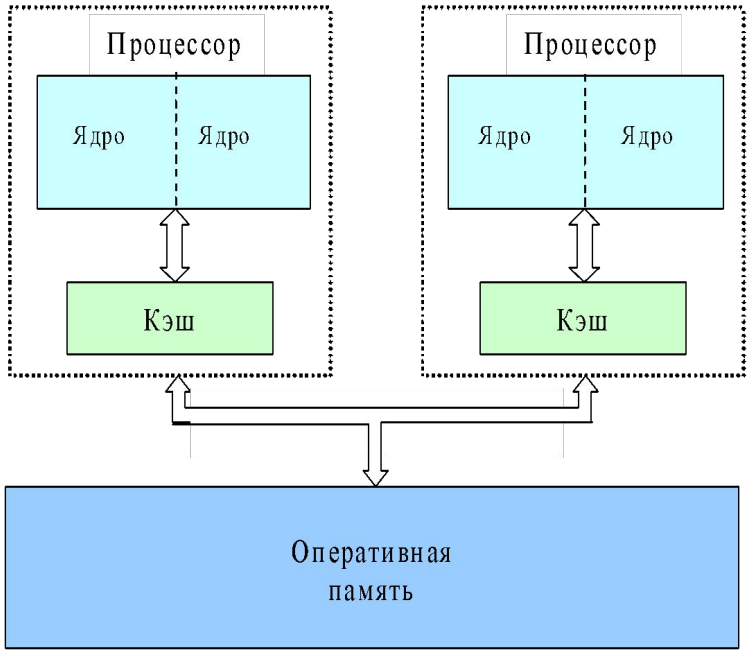

Системы с общей памятью описываются в виде модели параллельного компьютера с произвольным доступом к памяти (parallel random-access machine – PRAM).

Способы разработки программ для параллельных вычислений…

- ***Способ 1:*** автоматическое распараллеливание последовательных программ.
  - возможности автоматического построения параллельных программ ограничены.
- ***Способ 2:*** расширение существующих алгоритмических языков средствами параллельного программирования.
- ***Способ 3:*** использование новых алгоритмических языков параллельного программирования.

Примечание: Способы 2-3 приводят к необходимости значительной переработки существующего программного обеспечения.

Способы разработки программ для параллельных вычислений…

- ***Способ 4***: использование тех или иных ***внеязыковых средств языка программирования***.
  - Примеры средств – директивы или комментарии, которые обрабатываются специальным препроцессором до начала компиляции программы.
  - Директивы дают ***указания*** на возможные способы распараллеливания программы, при этом ***исходный текст программы остается неизменным***.
  - Препроцессор заменяет ***директивы*** параллелизма ***на дополнительный программный код*** (как правило, в виде обращений к процедурам параллельной библиотеки).
  - При отсутствии препроцессора компилятор построит исходный последовательный программный код.

Способы разработки программ для параллельных вычислений

- ***Способ 4: Положительные стороны*:**
  - ***Снижает потребность переработки существующего программного кода.***
  - ***Обеспечивает единство программного кода для последовательных и параллельных вычислений***, что снижает сложность развития и сопровождения программ.
  - **Позволяет осуществлять поэтапную (инкрементную) разработку параллельных программ.**

Именно этот подход и является основой технологии OpenMP

Принципы организации параллелизма…

- Использование потоков (общее адресное пространство).
- «Пульсирующий» (fork-join) параллелизм.

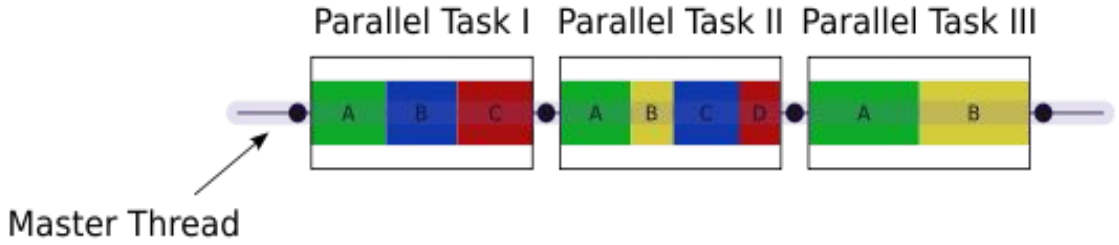

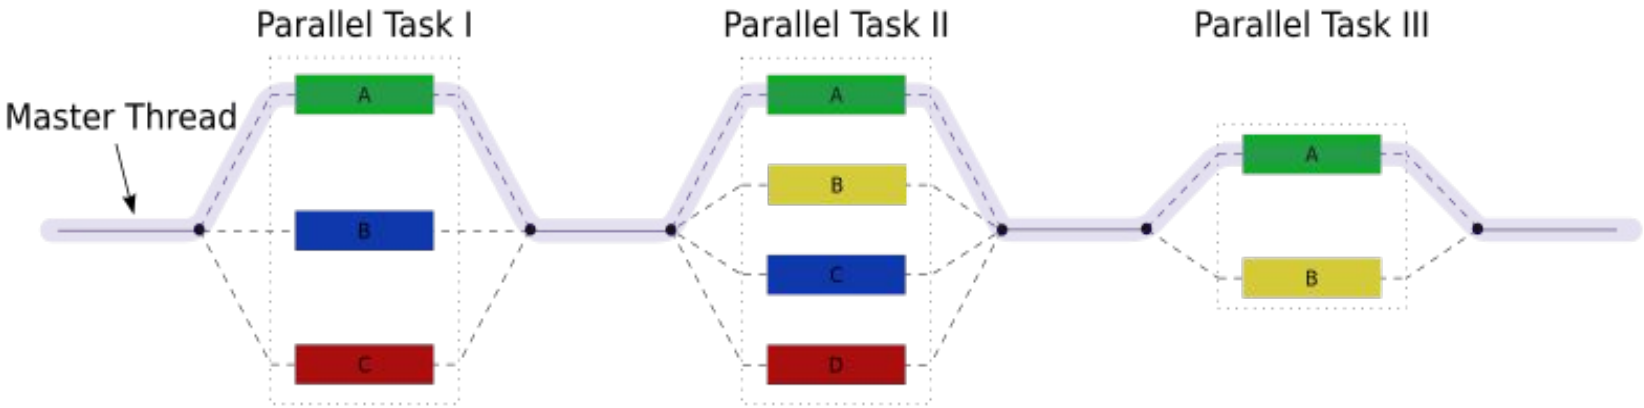

*Источник: http://en.wikipedia.org/wiki/OpenMP

Принципы организации параллелизма

- При выполнении обычного кода (вне параллельных областей) программа исполняется одним потоком *(master thread)*.
- При появлении директивы **`parallel`** происходит создание “команды” (*team*) потоков для параллельного выполнения вычислений.
- После выхода из области действия директивы **`parallel`** происходит синхронизация, все потоки, кроме *master*, уничтожаются (или приостанавливаются).
- Продолжается последовательное выполнение кода (до очередного появления директивы **`parallel`**).

Структура OpenMP

- Компоненты:
  - Набор директив компилятора.
  - Библиотека функций.
  - Набор переменных окружения.

- Изложение материала будет проводиться на примере языка C/C++.

ДИРЕКТИВЫ OPENMP

Формат, области видимости, типы.

Директива определения параллельной области.

Формат записи директив…

- **Формат**:

```
#pragma omp имя_директивы [параметр,…]
```

- Пример:

```
#pragma omp parallel default(shared) private(beta,pi)
```

Примечание: На английском языке для термина «параметр» используется обозначение «clause».

Области видимости директив

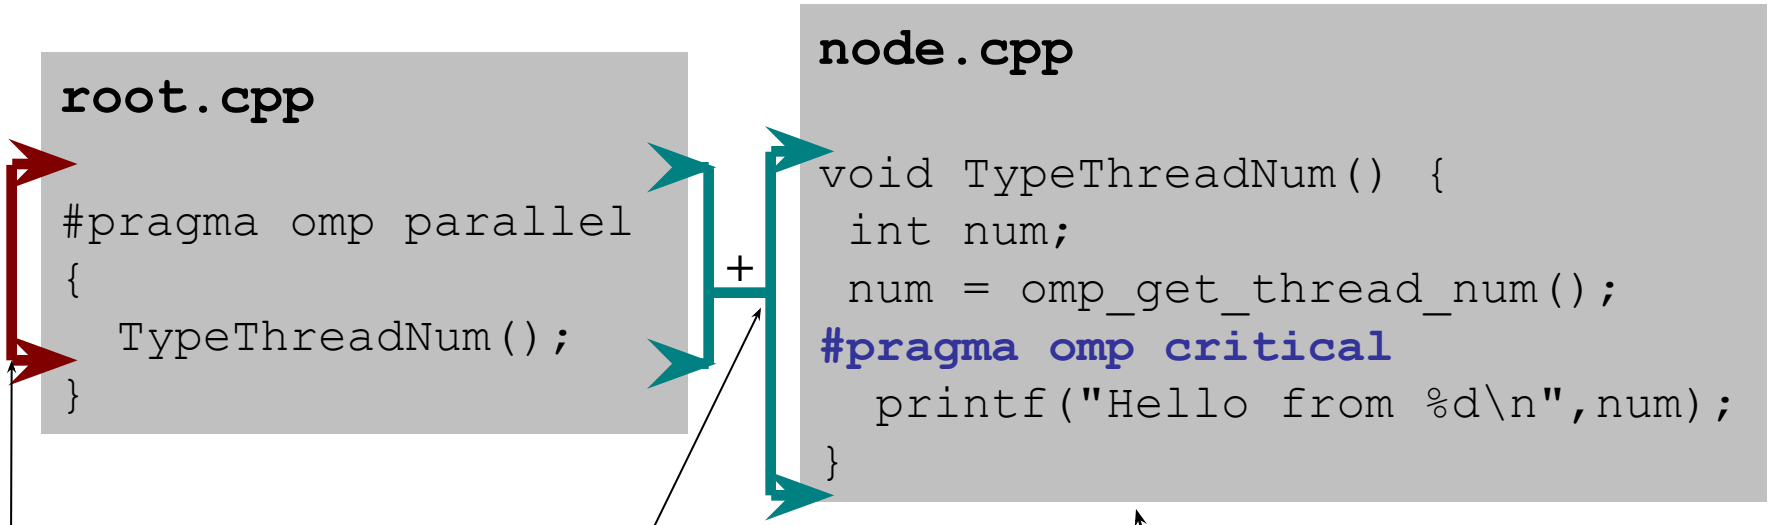

Статический (лексический) контекст параллельной области – блок, следующий за директивой **`parallel`**.

Динамический контекст параллельной области (включает статический контекст) – все функции из блока **`parallel`**.

Отделяемые (*orphaned*) директивы – директивы синхронизации и распределения работы. Могут появляться вне параллельной области.

Типы директив

- Определение параллельной области.
- Разделение работы.
- Синхронизация.

Определение параллельной области

- Директива **`parallel`** (основная директива OpenMP):
  - Когда основной поток выполнения достигает директиву **`parallel`** , создается набор (*team*) потоков.
  - Входной поток является основным потоком (*master thread*) этого набора и имеет номер 0.
  - Код области дублируется или разделяется между потоками для параллельного выполнения.
  - В конце области обеспечивается синхронизация потоков – выполняется ожидание завершения вычислений всех потоков.
  - Далее все потоки завершаются, и последующие вычисления продолжает выполнять только основной поток.

Формат директивы

- Формат директивы **parallel** :

```
#pragma omp parallel [clause ...]
  structured_block
```

- Возможные параметры (**clauses**):

```
if (scalar_expression)
private (list)
firstprivate (list)
default (shared | none)
shared (list)
copyin (list)
reduction (operator: list)
num_threads(integer-expression)
```

Пример использования директивы…

```
#include <omp.h>
void main() {
  int nthreads, tid;
  // Создание параллельной области
  #pragma omp parallel private(tid)
  {
    // печать номера потока
    tid = omp_get_thread_num();
    printf("Hello World from thread = %d\n", tid);
    // Печать количества потоков – только master
    if (tid == 0) {
      nthreads = omp_get_num_threads();
      printf("Number of threads = %d\n", nthreads);
    }
  } // Завершение параллельной области
}
```

Пример использования директивы

- Пример результатов выполнения программы для четырех потоков

```
Hello World from thread = 1
Hello World from thread = 3
Hello World from thread = 0
Hello World from thread = 2
```

Примечание: Порядок печати потоков может меняться от запуска к запуску!!!

Установка количества потоков

- Способы задания (по убыванию старшинства)
  - Параметр директивы:
    `num_threads(N)`
  - Функция установки числа потоков:
    `omp_set_num_threads(N)`
  - Переменная окружения:
    `OMP_NUM_THREADS`
  - Число, равное количеству процессоров, которое “видит” операционная система.

Определение времени выполнения параллельной программы

```
double t1, t2, dt;
t1 = omp_get_wtime ();
…
t2 = omp_get_wtime ();
dt = t2 - t1;
```

ДИРЕКТИВЫ OPENMP

Управление областью видимости данных.

Директивы управления областью видимости

- Управление областью видимости обеспечивается при помощи параметров (**`clauses`**) директив:
  - **`shared`**, **`default`**
  - **`private`**
  - **`firstprivate`**
  - **`lastprivate`**
  - **`reduction`**, **`copyin`**.

- Параметры директив определяют, какие соотношения существуют между переменными последовательных и параллельных фрагментов выполняемой программы.

Параметр shared

- Параметр **shared** определяет список переменных, которые будут общими для всех потоков параллельной области.

```
#pragma omp parallel shared(list)
```

Примечание: правильность использования таких переменных должна обеспечиваться программистом.

Параметр private

- Параметр **`private`** определяет список переменных, которые будут локальными для каждого потока.

```
#pragma omp parallel private(list)
```

- Переменные создаются в момент формирования потоков параллельной области.
- Начальное значение переменных является неопределенным.

Пример использования директивы private

```
#include <omp.h>
void main () {
  int nthreads, tid;
  // Создание параллельной области
  #pragma omp parallel private(tid)
  {
    // печать номера потока
    tid = omp_get_thread_num();
    printf("Hello World from thread = %d\n", tid);
    // Печать количества потоков – только master
    if (tid == 0) {
      nthreads = omp_get_num_threads();
      printf("Number of threads = %d\n", nthreads);
    }
  } // Завершение параллельной области
}
```

Параметр firstprivate

- Параметр **`firstprivate`** позволяет создать локальные переменные потоков, которые перед использованием инициализируются значениями исходных переменных.

```
#pragma omp parallel firstprivate(list)
```

Параметр lastprivate

- Параметр **`lastprivate`** позволяет создать локальные переменные потоков, значения которых запоминаются в исходных переменных после завершения параллельной области (используются значения потока, выполнившего последнюю итерацию цикла или последнюю секцию).

```
#pragma omp parallel lastprivate(list)
```

ДИРЕКТИВЫ OPENMP

Распределение вычислений между потоками

Директивы распределения вычислений между потоками

- Существует 3 директивы для распределения вычислений в параллельной области:
  - **`for`** – распараллеливание циклов.
  - **`sections`** – распараллеливание раздельных фрагментов кода (функциональное распараллеливание).
  - **`single`** – директива для указания последовательного выполнения кода.
- Начало выполнения директив по умолчанию не синхронизируется.
- Завершение директив по умолчанию является синхронным.

Директива for

- Формат директивы **for**:

```
#pragma omp for [clause ...]
  for loop
```

- Возможные параметры (**clause**):
  - **private(list)**
  - **firstprivate(list)**
  - **lastprivate(list)**
  - **schedule(kind[, chunk_size])**
  - **reduction(operator: list)**
  - **ordered**
  - **nowait**

Пример использования директивы for

```
#include <omp.h>
#define CHUNK 100
#define NMAX 1000
void main() {
  int i, n, chunk;
  float a[NMAX], b[NMAX], c[NMAX];
  for (i=0; i < NMAX; i++)
    a[i] = b[i] = i * 1.0;
  n = NMAX; chunk = CHUNK;
  #pragma omp parallel shared(a,b,c,n,chunk) private(i)
  {
    #pragma omp for
    for (i=0; i < n; i++)
      c[i] = a[i] + b[i];
  } // end of parallel section
}
```

Директива for. Параметр schedule

- **`static`** – итерации делятся на блоки по **`chunk`** итераций и статически разделяются между потоками.
  - Если параметр **`chunk`** не определен, итерации делятся между потоками равномерно и непрерывно.
- **`dynamic`** – распределение итерационных блоков осуществляется динамически (по умолчанию **`chunk=1`**).
- **`guided`** – размер итерационного блока уменьшается экспоненциально при каждом распределении.
  - **`chunk`** определяет минимальный размер блока (по умолчанию **`chunk=1`**).
- **`runtime`** – правило распределения определяется переменной **`OMP_SCHEDULE`** (при использовании **`runtime`** параметр **`chunk`** задаваться не должен).

Пример использования директивы for

```
#include <omp.h>
#define CHUNK 100
#define NMAX 1000
void main() {
  int i, n, chunk;
  float a[NMAX], b[NMAX], c[NMAX];
  for (i=0; i < NMAX; i++)
    a[i] = b[i] = i * 1.0;
  n = NMAX; chunk = CHUNK;
  #pragma omp parallel shared(a,b,c,n,chunk) private(i)
  {
    #pragma omp for schedule(dynamic,chunk)
    for (i=0; i < n; i++)
      c[i] = a[i] + b[i];
  } // end of parallel section
}
```

Директива sections…

- Формат директивы **sections**:

```
#pragma omp sections [clause ...]
  {
    #pragma omp section // несколько секций
      structured_block
}
```

- Возможные параметры (**clause**):
  - **private(list)**,
  - **firstprivate(list)**,
  - **lastprivate(list)**,
  - **reduction(operator: list)**,
  - **nowait**

Директива sections

- Директива **`sections`** – распределение вычислений для раздельных фрагментов кода.

- Фрагменты кода:
  - Выделяются при помощи директивы **`section`**.
  - Каждый фрагмент выполняется однократно.
  - Разные фрагменты выполняются разными потоками.
  - Завершение директивы по умолчанию синхронизируется
  - Директивы **`section`** должны использоваться только в статическом контексте.

Пример использования директивы sections…

```
#include <omp.h>
#define NMAX 1000
void main() {
  int i, n;
  float a[NMAX], b[NMAX], c[NMAX];
  for (i=0; i < NMAX; i++)
    a[i] = b[i] = i * 1.0;
  n = NMAX;
  #pragma omp parallel shared(a,b,c,n) private(i)
  {
    // продолжение на следующем слайде
```

Пример использования директивы sections

```
    #pragma omp sections nowait
    {
      #pragma omp section
        for (i=0; i < n/2; i++)
          c[i] = a[i] + b[i];
      #pragma omp section
        for (i=n/2; i < n; i++)
          c[i] = a[i] + b[i];
    } // end of sections
  } // end of parallel section
}
```

Объединение директив parallel и for/sections

```
#include <omp.h>
#define CHUNK 100
#define NMAX 1000
void main () {
  int i, n, chunk;
  float a[NMAX], b[NMAX], c[NMAX];
  for (i=0; i < NMAX; i++)
    a[i] = b[i] = i * 1.0;
  n = NMAX;
  chunk = CHUNK;
  #pragma omp parallel for shared(a,b,c,n) \
    schedule(static,chunk)
    for (i=0; i < n; i++)
      c[i] = a[i] + b[i];
}
```

ДИРЕКТИВЫ OPENMP

Операция редукции

Параметр reduction

- Параметр **`reduction`** определяет список переменных, для которых выполняется операция редукции (объединения).

```
reduction (operator: list)
```

- Перед выполнением параллельной области для каждого потока создаются копии этих переменных.
- Потоки формируют значения в своих локальных переменных.
- При завершении параллельной области на всеми локальными значениями выполняются необходимые операции редукции, результаты которых запоминаются в исходных (глобальных) переменных.

Пример использования параметра reduction

```
#include <omp.h>
void main() { // vector dot product
  int i, n, chunk;
  float a[100], b[100], result;
  n = 100; chunk = 10;
  result = 0.0;
  for (i=0; i < n; i++) {
    a[i] = i * 1.0; b[i] = i * 2.0;
  }
  #pragma omp parallel for default(shared) \
    schedule(static,chunk) reduction(+:result)
  for (i=0; i < n; i++)
    result = result + (a[i] * b[i]);
  printf("Final result= %f\n",result);
}
```

Правила записи параметра reduction

- Возможный формат записи выражения:
  - **`x = x op expr`**
  - **`x = expr op x`**
  - **`x binop = expr`**
  - **`x++, ++x, x--, --x`**
- **`x`** должна быть скалярной переменной.
- **`expr`** не должно ссылаться на **`x`**.
- **`op`** (operator) должна быть неперегруженной операцией вида:

  `+, -, *, /, &, ^, |, &&, ||`
- **`binop`** должна быть неперегруженной операцией вида:

  `+, -, *, /, &, ^, |`

Заключение

- Данная лекция посвящена рассмотрению методов параллельного программирования для вычислительных систем с общей памятью с использованием технологии OpenMP.
- В лекции проводится обзор технологии OpenMP.
- Рассматриваются директивы OpenMP, позволяющие
  - определять параллельные области,
  - управлять областью видимости данных,
  - распределять вычислений между потоками,
  - выполнять операции редукции.
- Дальнейшее изучение технологии OpenMP будет продолжено в одной из следующих лекций.

Литература

Гергель В.П. Высокопроизводительные вычисления для многопроцессорных многоядерных систем. - М.: Изд-во Московского университета, 2010. – 544 с.

- Дополнительная литература:
  - **Воеводин В.В., Воеводин Вл.В.** Параллельные вычисления. – СПб.: БХВ-Петербург, 2002.
  - **Гергель В.П.** Теория и практика параллельных вычислений. - М.: Интернет-Университет, БИНОМ. Лаборатория знаний, 2007.
  - **Гергель В.П.** Новые языки и технологии параллельного программирования. - М.: Издательство Московского университета, 2012. – 434 с.
  - **Гергель В.П., Баркалов К.А., Мееров И.Б., Сысоев А.В.** и др. Параллельные вычисления. Технологии и численные методы. Учебное пособие в 4 томах. – Нижний Новгород: Изд-во Нижегородского госуниверситета, 2013. – 1394 с.