OpenMP

Параллельное программирование для многоядерных систем

http://www.openmp.org.

Концепция OpenMP

Интерфейс OpenMP задуман как стандарт параллельного программирования для многопроцессорных систем с общей памятью

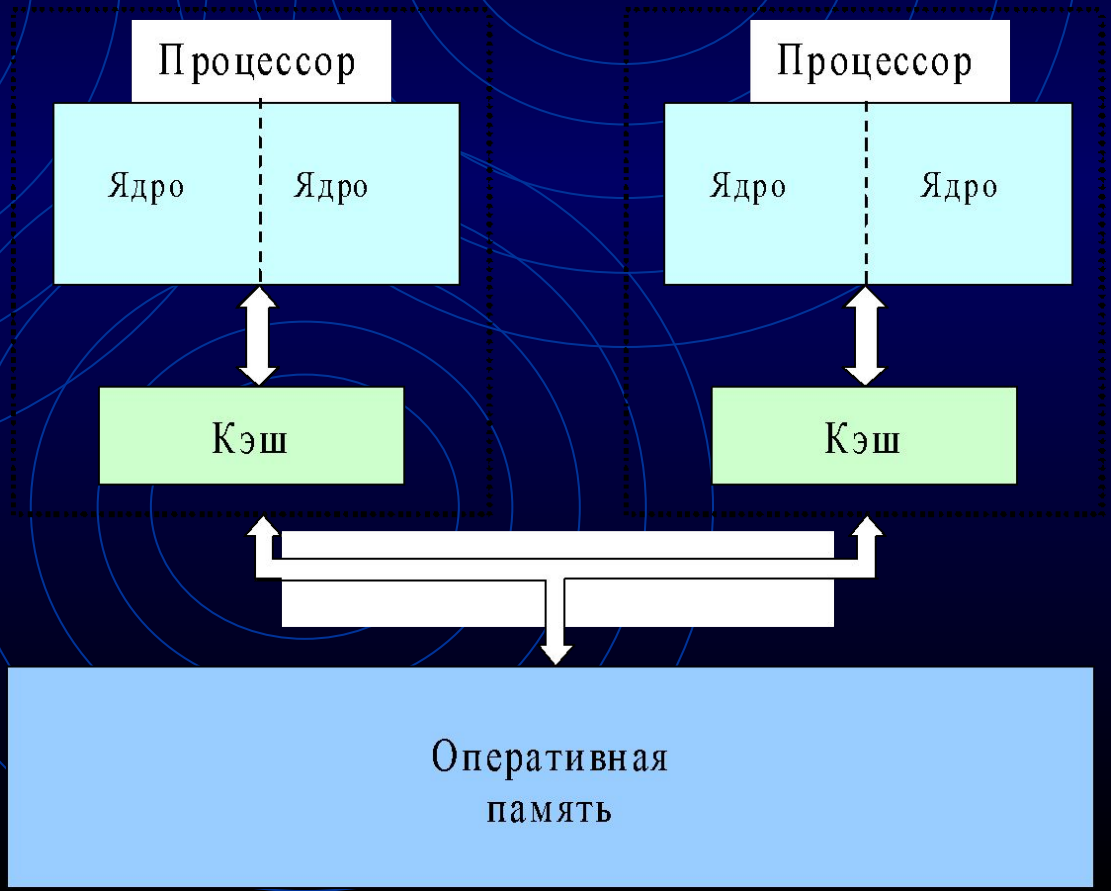

Положительные качества OpenMP

Поэтапное распараллеливание

Можно распараллеливать последовательные программы поэтапно, не меняя их структуру

Единственность разрабатываемого кода

Нет необходимости поддерживать последовательный и параллельный вариант программы, поскольку директивы игнорируются обычными компиляторами (в общем случае)

Переносимость

Поддержка большим числом компиляторов под разные платформы и ОС, стандарт для распространенных языков C/C++, Fortran

Принципы организации параллелизма

Использование потоков на общем адресном пространстве

Пульсирующий (fork-join) параллелизм

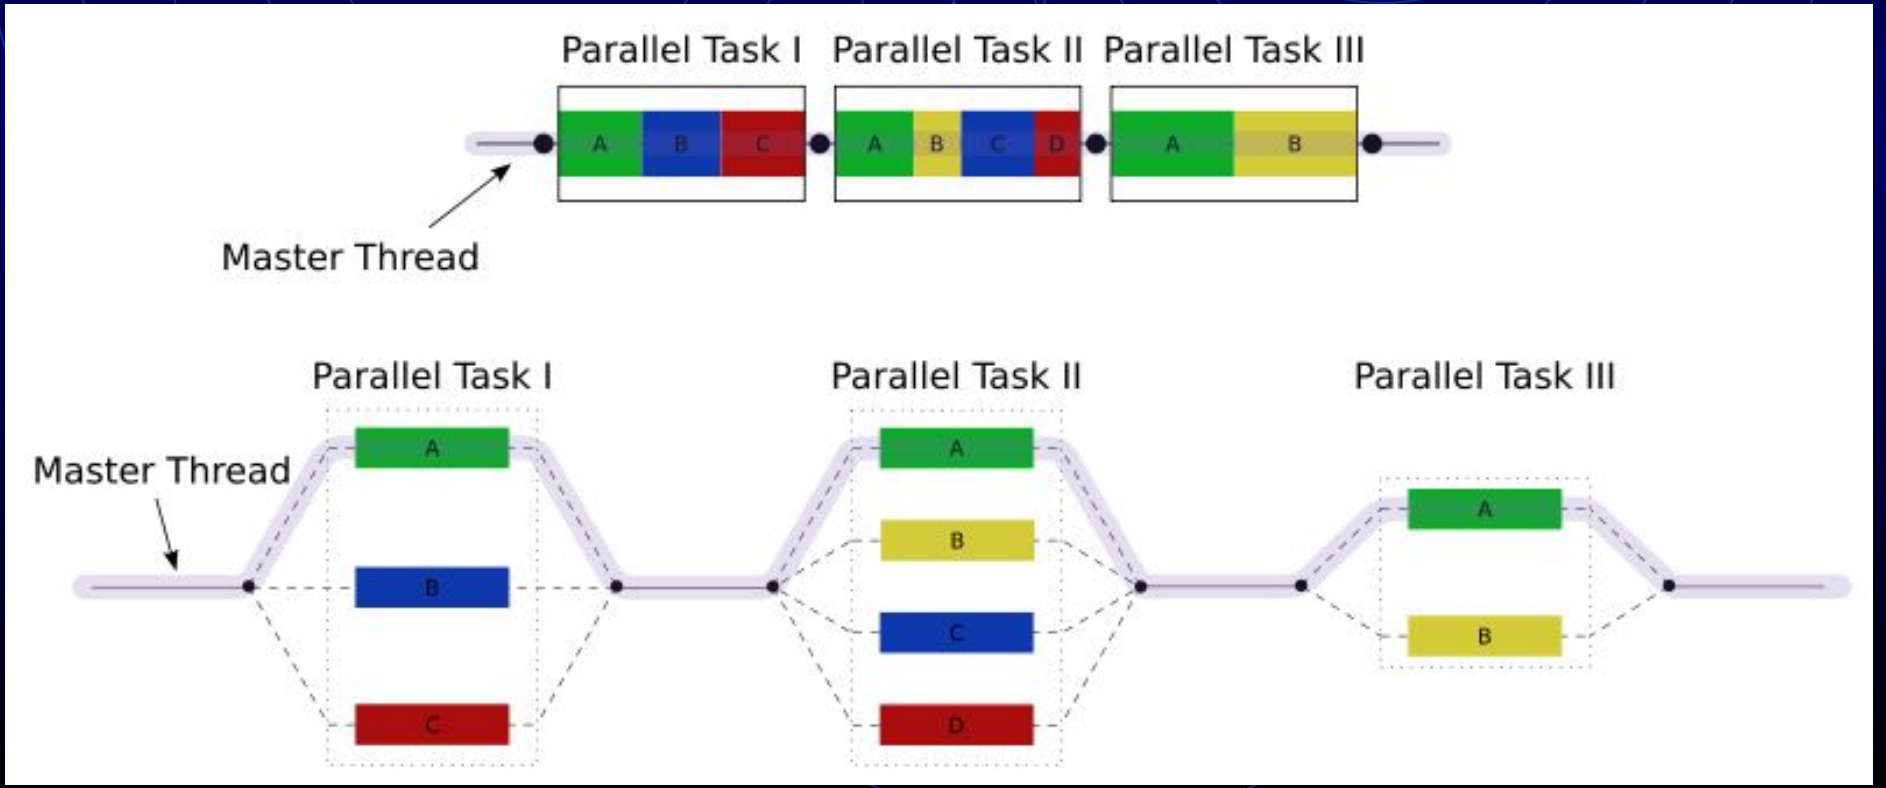

Принципы организации параллелизма

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

Когда следует использовать технологию Open MP

- Целевая платформа является многопроцессорной или многоядерной
- Выполнение циклов нужно распараллелить
- Перед выпуском приложения нужно повысить его быстродействие
- Параллельное приложение должно быть кроссплатформенным

Когда эффективно использовать технологию Open MP

- Параллельная версия настигает по быстродействию последовательную или при большом количестве итераций или при большом объеме вычислений внутри параллельных фрагментов кода

Настройки компилятора Microsoft Visual Studio

- Project
  - Property Pages
  - C/C++
  - Language
  - OpenMP Support
  - Yes

Средства openMP

Категории:

- Функции времени выполнения
- Функции инициализации/завершения
- Переменные среды окружения
- Параллельные регионы
- Распределение работ и диспетчеризация
- Синхронизация и блокировка

Структура программы

```
#include <omp.h>

int main(){
        // по умолчанию  кол-во потоков:
int numTh = omp_get_num_threads();
        // сами ставим кол-во потоков
omp_set_num_threads(4);
#pragma omp parallel
…
return 0;
}
```

Простейшая программа

```
#include <omp.h>
#include <stdio.h>
int main (int argc,  char * argv[])  {
 #pragma omp parallel
   {
     printf("Hello world\n");
   }
printf("\nset num_threads=16\n");
omp_set_num_threads(16);
#pragma omp parallel
   {
     printf("Hello world\n");
   }
return 0;
}
```

Простейшая программа – результат работы

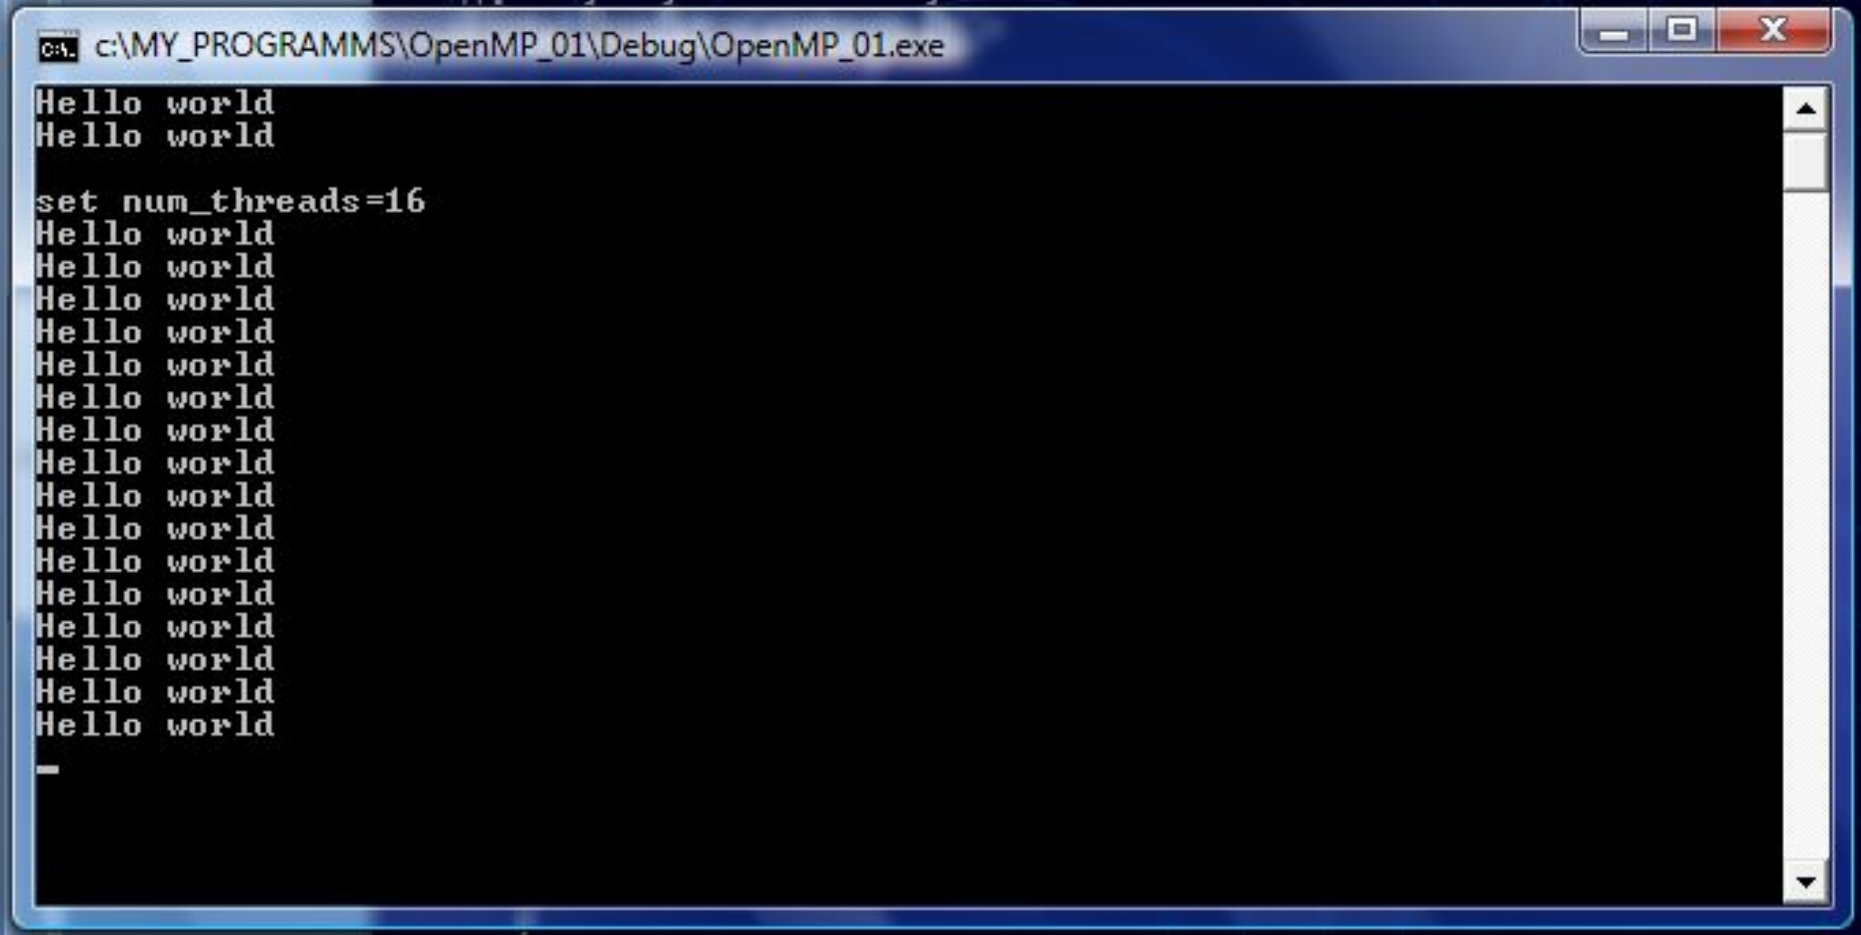

Простейшие директивы OpenMP

```
#pragma omp parallel
{
    <код>
}
// выполнится столько  раз, сколько потоков

#pragma omp parallel for
for (int i=0; i<n; i++){
    <код>
}
// выполнится n  раз с разделением нагрузки между потокам
```

Ограничения на оператор for OpenMP

1. Переменная цикла должна иметь тип integer.
2. Цикл должен являться базовым блоком и не может использовать goto и break (за исключением оператора exit, который завершает все приложение).
3. Инкрементная часть цикла for должна являться либо целочисленным сложением, либо целочисленным вычитанием.
4. Если используется операция сравнения < или <=, переменная цикла должна увеличиваться при каждой итерации, а при использовании операции > или >= переменная цикла должна уменьшаться.

Пример 1

```
#pragma omp parallel num_threads(2)
  for (int i = 0; i < 10; i++)
          myFunc();
//  при запуске  будет выполняться по одному разу в
//  каждом потоке, и вместо ожидаемых 10 раз
//  функция myFunc будет вызвана 20 раз.

#pragma omp parallel for num_threads(2)
  for (int i = 0; i < 10; i++)
         myFunc();
// цикл будет выполнен 10 раз, разделенный
// между двумя потоками
```

Пример 1-а (parallel без указания количества потоков)

```
#pragma omp parallel
  for (int i = 0; i < 10; i++)
          myFunc();
//  при запуске  будет выполняться по одному разу в
//  каждом потоке, и вместо ожидаемых 10 раз
//  функция myFunc будет вызвана 20 раз при двух процессорах

#pragma omp parallel for
  for (int i = 0; i < 10; i++)
          myFunc();
// цикл будет выполнен 10 раз, разделенный
// между двумя потоками на двухпроцессорном компьютере
```

Пример 2 (ошибка!)

```
#pragma omp parallel num_threads(2)
{
    ... // N строк кода
    #pragma omp parallel for
    for (int i = 0; i < 10; i++)    {
                    myFunc();
    }
  }
//  в двух потоках выполнятся два
//  параллельных цикла
//  функция myFunc будет вызвана 20 раз.
```

Пример 2 - правильно

```
#pragma omp parallel num_threads(2)
{
    ... // N строк кода
    #pragma omp for
    for (int i = 0; i < 10; i++)    {
                    myFunc();
    }
  }
```

Ограничение на переопределение количества потоков

Количество потоков нельзя переопределять внутри параллельной секции. Это приводит к ошибкам во время выполнения программы и ее аварийному завершению.

```
#pragma omp parallel
  {
    omp_set_num_threads(2); // ощибка !!!!
    #pragma omp for
    for (int i = 0; i < 10; i++)
                  myFunc();
  }
```

Планирование и разбиение циклов

Static scheduling – цикл делится на фрагменты одинакового размера

Dynamic scheduling – фрагменты помещаются в очередь, освободившийся поток будет брать следующую «порцию».

Guided scheduling == Dynamic scheduling с изменяемым размером фрагмента в процессе выполнения

Планирование и разбиение циклов (Static scheduling - пример работы)

```
int s;
#pragma omp parallel for private (s)
for (int i=0; i<10; i++){
      s =   omp_get_thread_num();
      Sleep(1000*i);
      printf("Hello world from thread = %d\n",s);
}
```

Планирование и разбиение циклов (Static scheduling - пример работы)

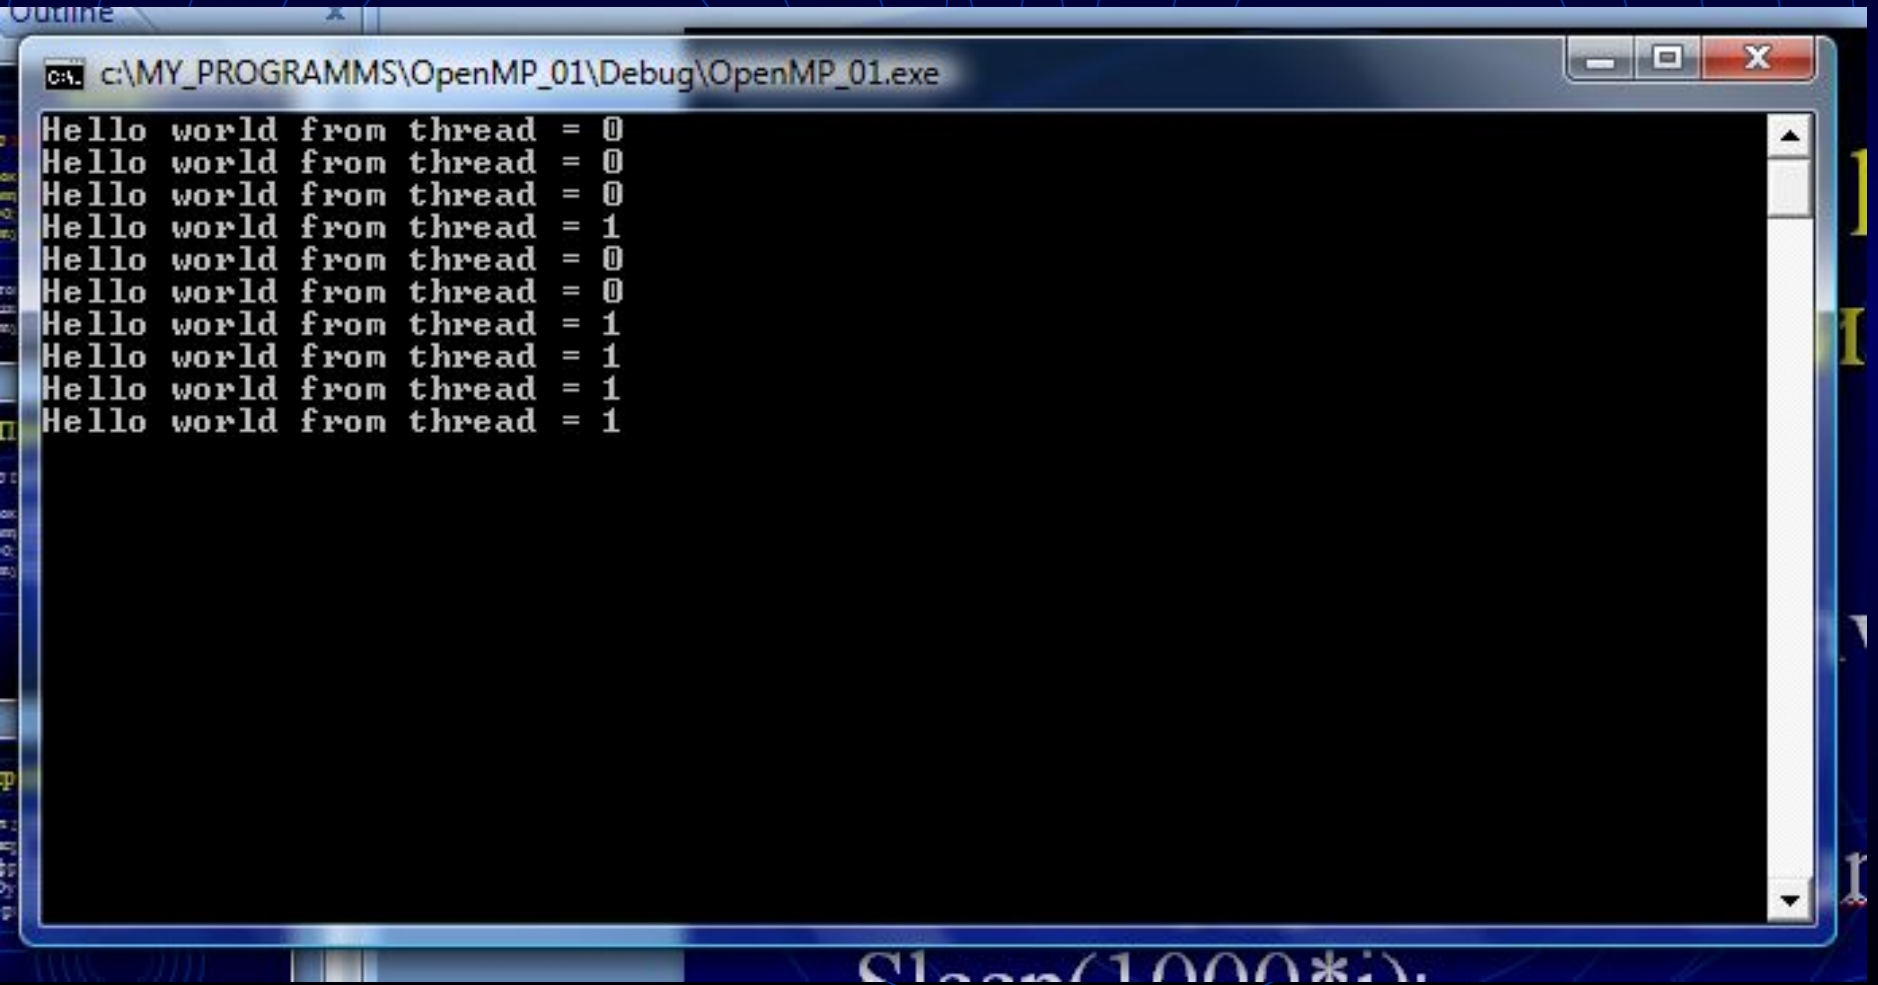

Планирование и разбиение циклов (Dinamic scheduling - пример работы)

```
int s;
#pragma omp parallel for private (s)schedule(dynamic, 2)
for (int i=0; i<10; i++){
      s =   omp_get_thread_num();
      Sleep(1000*i);
      printf("Hello world from thread = %d\n",s);
}
```

Планирование и разбиение циклов
Dinamic scheduling - пример работы
schedule(dynamic, 2)

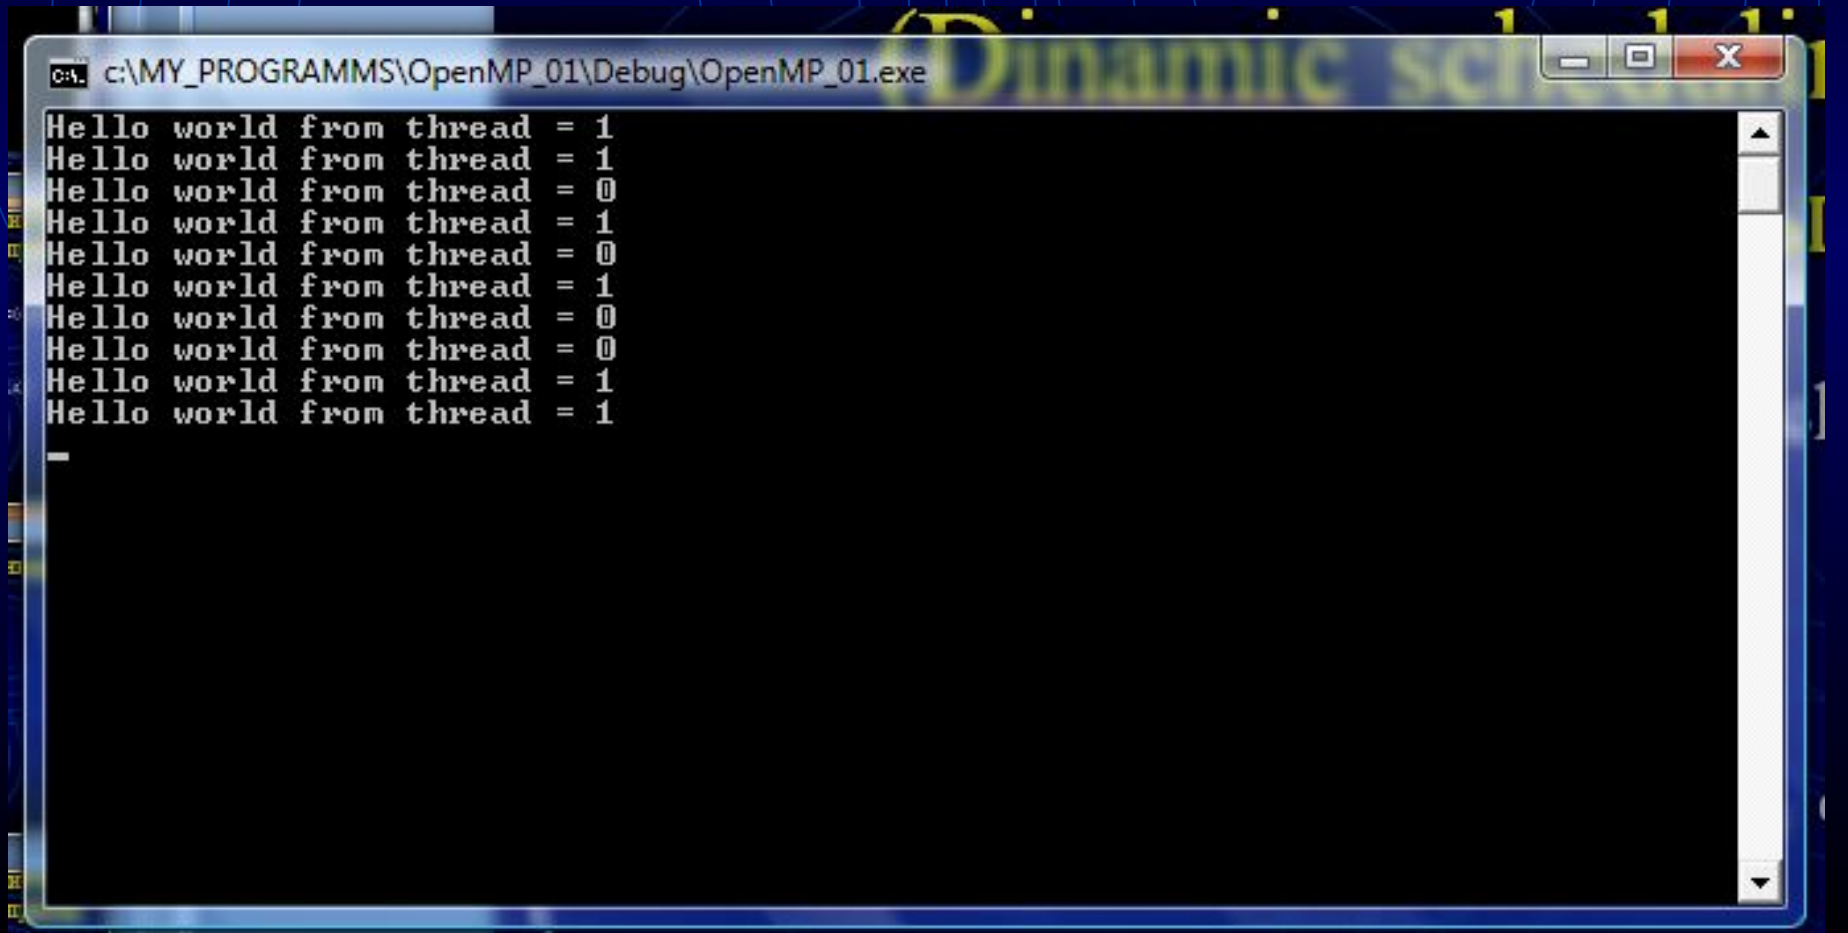

Планирование и разбиение циклов
Dinamic scheduling - пример работы
schedule(dynamic, 1)

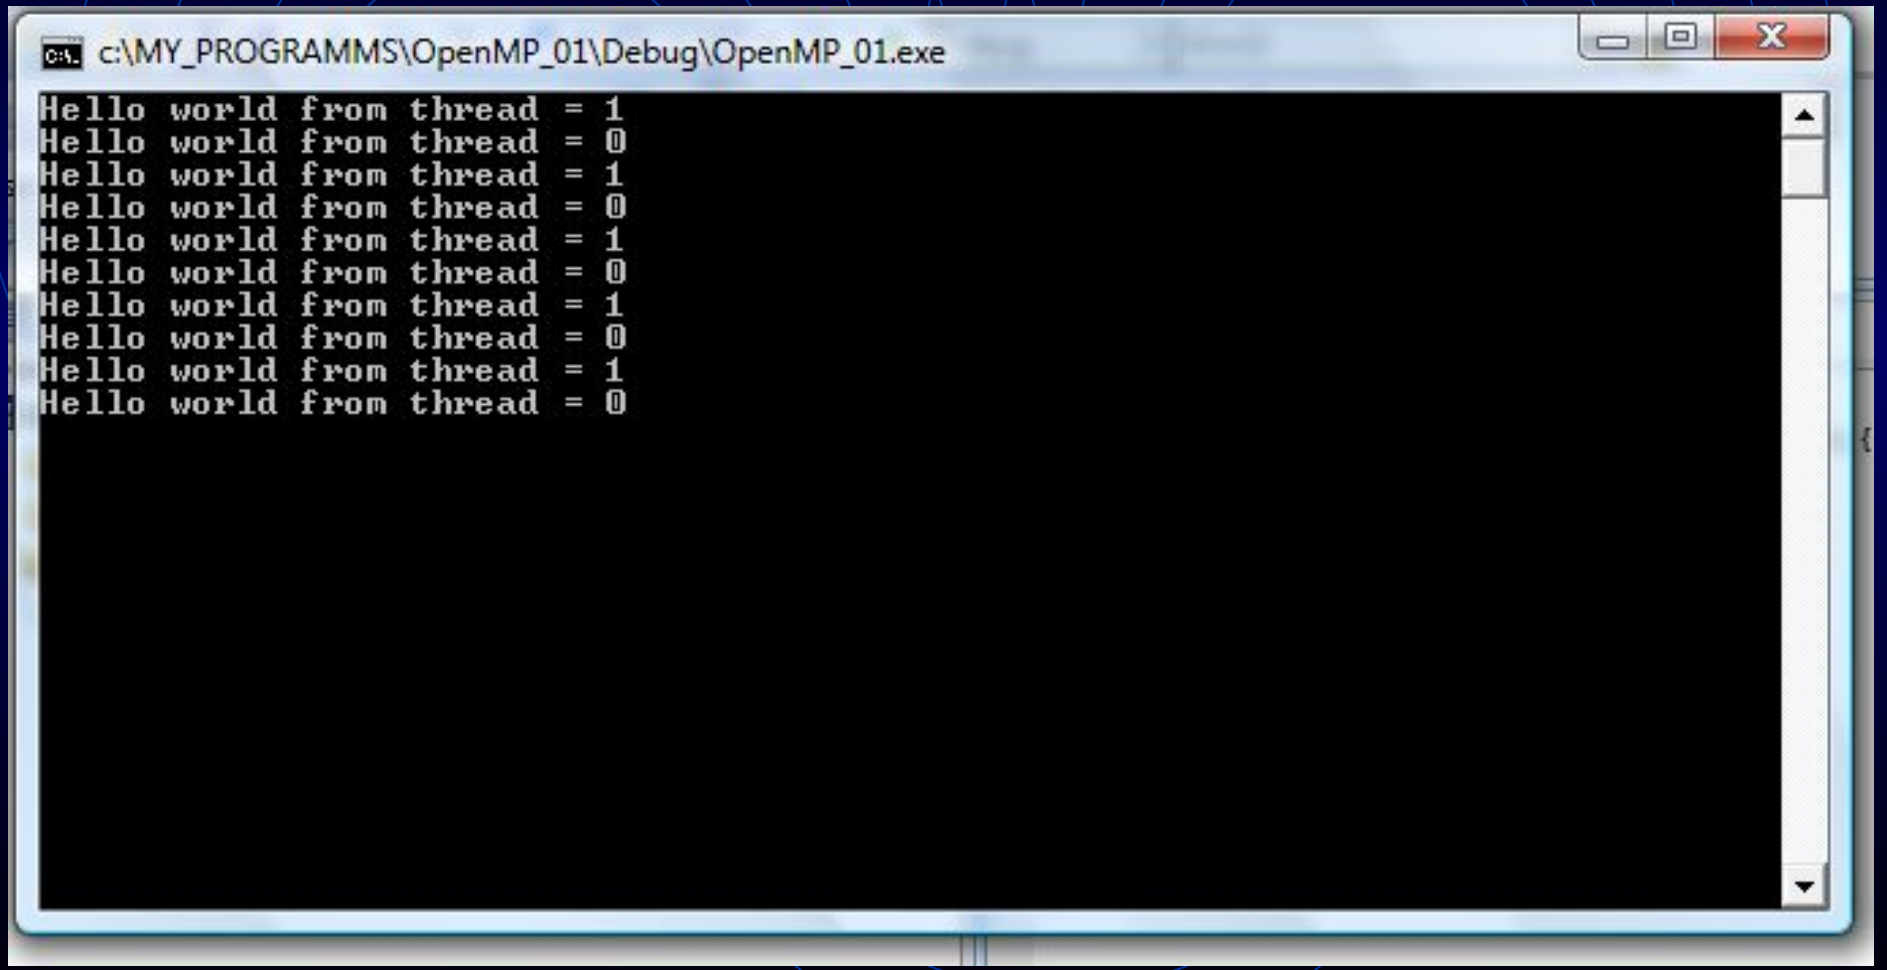

Dinamic scheduling - пример работы для быстрых операций во втором потоке и медленных в первом

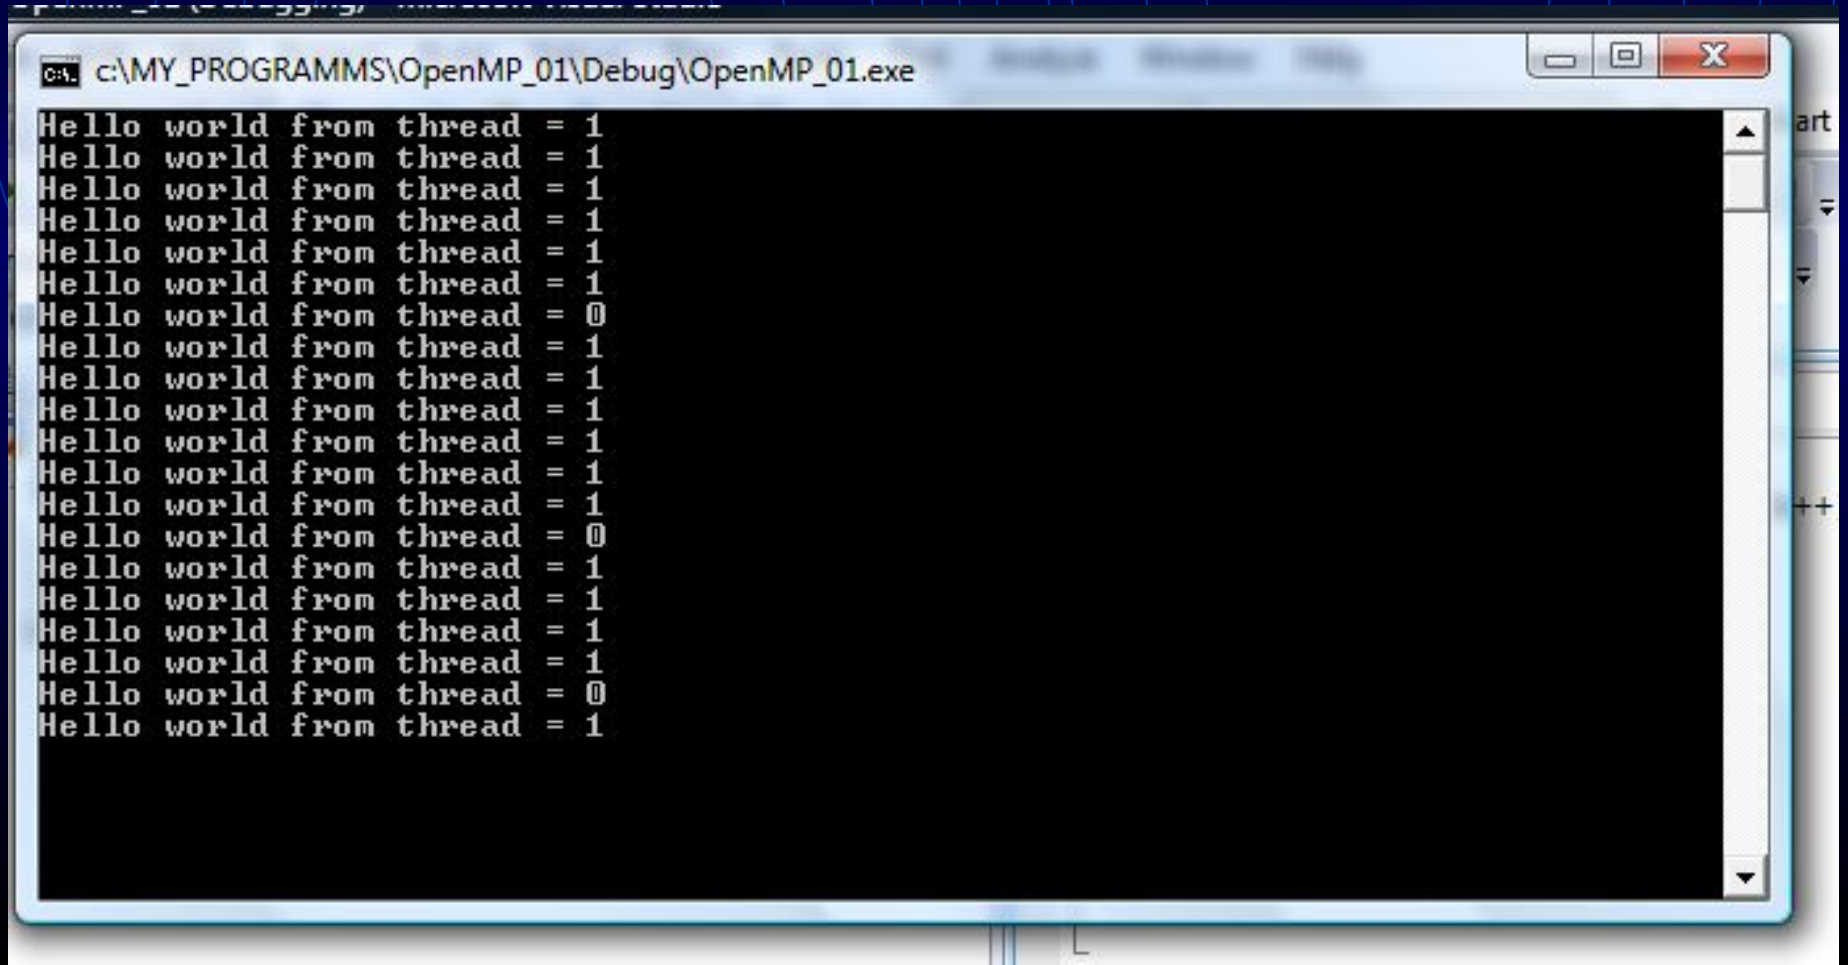

Вывод данных в консоль в параллельных потоках - операция ОЧЕНЬ опасная!!!

Операция вывода строки на экран не является атомарной. Следовательно, два потока будут выводить свои символы одновременно.

Возможны гонки данных

Вывод данных в консоль в параллельных потоках надо оградить блокировкой

```
#pragma omp parallel num_threads(2)
 {
  #pragma omp critical
  {
     printf("Hello World \n");
  }
```

Гонки данных
Незащищенный доступ к общей памяти

```
double data;
#pragma omp parallel  for
    for (int i = 0; i < 10; i++)    {
        data=array[i];
                array[i] = func(data);
 // гонки данных!!
// переменная data    одна для всех  потоков
    }
```

Гонки данных

Незащищенный доступ к общей памяти

ПРИЧИНА:
все глобальные переменные в OpenMP считаются shared по умолчанию/

РЕШЕНИЕ (первый вариант):
просто объявлять соответствующие переменные как локальные переменные в параллельных секциях.

Приватные переменные - метод борьбы с гонками данных

```
double data;
#pragma omp parallel  for
    for (int i = 0; i < 10; i++)    {
        data=array[i];
                array[i] = func(data);
 // гонки данных!!
    }
```

 заменим код

Локальные переменные становятся приватными – первый вариант решения

```
// double data; // удалили внешнее объявление!
#pragma omp parallel  for
    for (int i = 0; i < 10; i++)    {
        double  data=array[i];
                array[i] = func(data);
// переменная, объявленная внутри
// параллельной конструкции – приватная
 }
```

Явно указанные приватные переменные – решение, эквивалентное по результату

```
double data;
#pragma omp parallel  for  private(data)
    for (int i = 0; i < 10; i++)    {
        data=array[i];
// переменная объявлена приватной в потоке
// гонки данных отсутствуют!!
                array[i] = func(data);
    }
```

Приватные переменные – возможные ошибки

1. При входе в поток для переменных, являющиеся параметрами выражений private, создаются локальные копии. Эти копии являются неинициализированными по умолчанию. Следовательно, любая попытка работы с ними без предварительной инициализации приведет к ошибке во время выполнения программы.
2. Забытое выражение private и работа с переменной вне параллельной секции. Значения таких переменных после соответствующей параллельной секции являются непредсказуемыми.

Приватные переменные – ограничения

Переменная в выражении private не должна иметь ссылочный тип.

Причина ограничения очевидна – если переменная будет указателем, то каждый поток получит по локальной копии этого указателя, и в результате все потоки будут работать через него с общей памятью.

Правила разделения переменных (1)

Неявное правило 1: Все переменные, определенные вне `omp parallel`, являются глобальными для всех потоков

Неявное правило 2: Все переменные, определенные внутри `omp parallel`, являются локальными для каждого потока

Неявное исключение: В прагме `omp for`, счетчик цикла всегда локален для каждого потока

Правила разделения переменных (2)

Явное правило 1: Переменные, приведенные в `shared()`, являются глобальными для всех потоков

Явное правило 2: Переменные, приведенные в `private()`, являются локальными для каждого потока

Параллельные секции

```
#pragma omp parallel  sections
// создан параллельный регион секций
  {
#pragma omp section
    <код>
#pragma omp section
    <код>
   }
// все секции выполняются одновременно в
// разных потоках
```

Параллельные секции

- Директива sections – распределение вычислений для раздельных фрагментов кода
- Фрагменты 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

Редукции в циклах

```
int sum =0;
#pragma omp parallel  for reduction (+ sum)
 {
for (int i=0; i<1000; i++)
    sum  = sum + func(i);
 }
// reduction  означает:
// -- создание приватной копии  sum  в
//     каждом   потоке
// -- после завершения цикла сложение
 //     значений всех приватных копий в  sum
```

Редукции в циклах

Параметр reduction определяет список переменных, для которых выполняется операция редукции

- перед выполнением параллельной области для каждого потока создаются копии этих переменных,
- потоки формируют значения в своих локальных переменных
- при завершении параллельной области над всеми локальными значениями выполняются необходимые операции редукции, результаты которых запоминаются в исходных (глобальных) переменных

Барьеры

```
int sum =0;
#pragma omp parallel  for reduction (+ sum)
 {
for (int i=0; i<1000; i++)
    sum  = sum + func(i);
 }
// продолжение работы возможно только
// только при завершении всех потоков

// барьер == конец parallel  for
 // барьер == конец parallel  sections
```

Барьеры и nowait

В некоторых случаях возникает потребность отключать синхронизацию,

Для этого существует оператор nowait

Это может быть выгодно, если за циклом следует второй цикл, данные в котором НЕ ЗАВИСЯТ от результатов первого цикла.

Барьеры и nowait

```
#pragma omp parallel
{
#pragma omp for nowait
        for(int i = 0; i < 5000; i++) {
                // …
        }
#pragma omp for
        for(int j = 0; j < 1000; j++) {
                // …
        }
#pragma omp barrier  // здесь ждем завершения
        some_func();  // код после барьера
}
```

Барьеры и nowait

В рассмотренном примере потоки, которые освободились после обработки первого цикла, переходят к обработке второго цикла без ожидания остальных потоков.

В некоторых случаях это может повысить производительность, поскольку уменьшается время простоя потоков.

#pragma omp barrier
Создание барьера после nowait

Критические секции

С помощью критических разделов можно предотвратить одновременный доступ к одному сегменту кода из нескольких потоков. Один поток получает доступ только тогда, когда другие не обрабатывают данный код. Конструкция имеет следующий вид:

```
#pragma omp critical
{
    …
}
```

Критические секции

Применение критических секций там, где они не нужны, нежелательно :

- из-за критических секций потокам приходится ждать друг друга, а это уменьшает приращение производительности, достигнутое благодаря распараллеливанию кода,
- на вход в критические секции и на выход из них также затрачивается некоторое время.

Выполнение в одном потоке внутри параллельного фрагмента

```
#pragma omp parallel num_threads(4)
 { …    // что-то выполняем параллельно в 4 потоках
   #pragma omp single     {
     int numTh = omp_get_num_threads();
     cout <<"\n”<<numThreads=“
<<numTh<<"\n“;
    }
 } //Директива single означает, что соответствующая
```

секция должна быть выполнена одним потоком. Этим потоком с равной вероятностью может оказаться любой из существующих

Выполнение в одном потоке внутри параллельного фрагмента

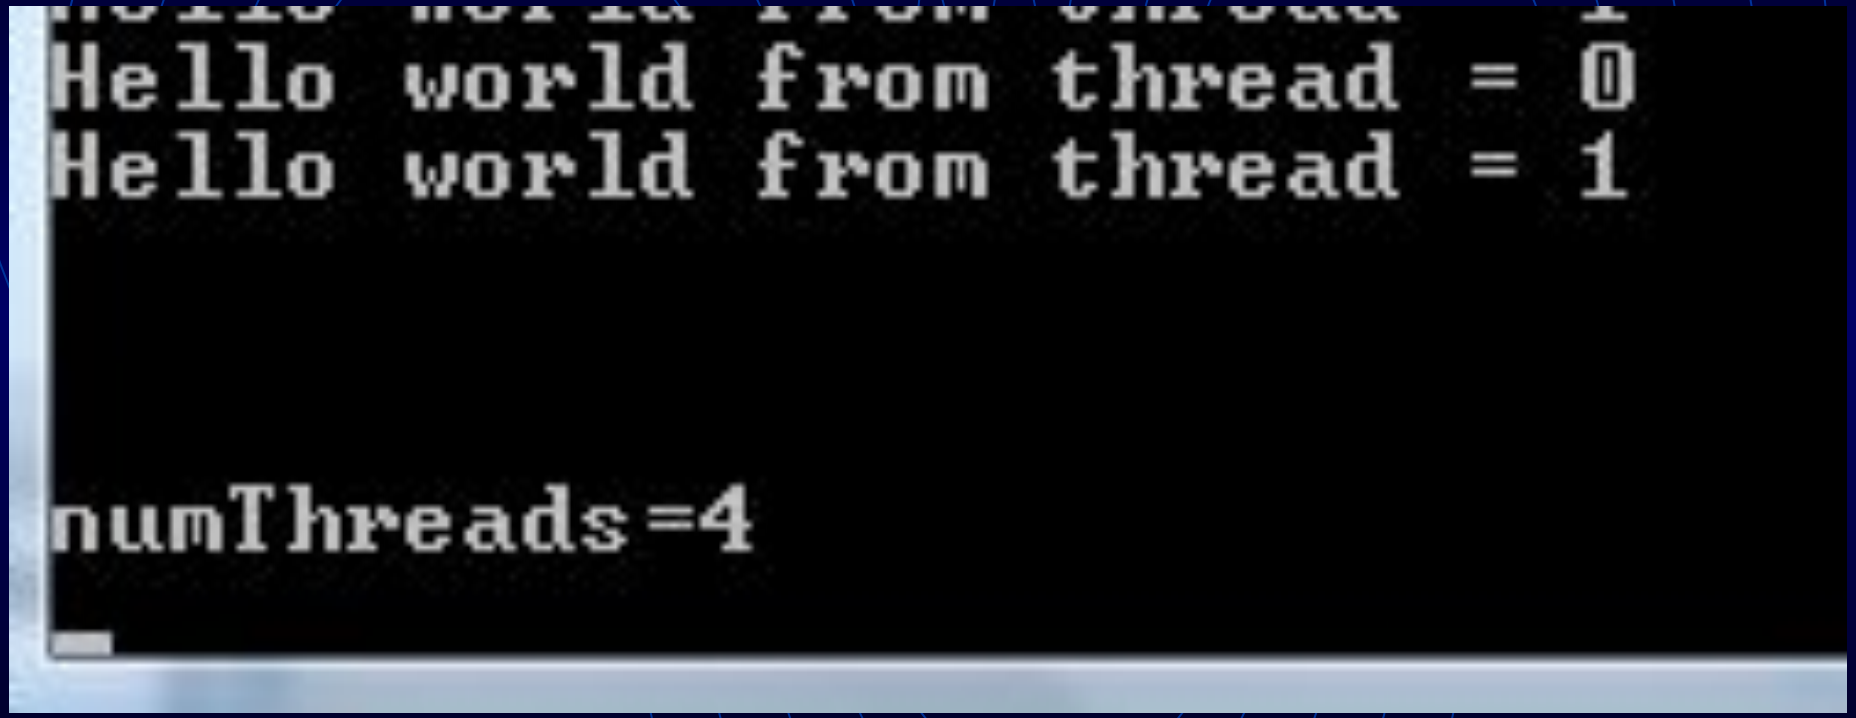

- Потоков 4, но сообщение выдано только одним потоком !

Два базовых типа конструкций OpenMP

- Директивы #pragma
- Функции исполняющей среды OpenMP

Функции OpenMP служат в основном для изменения и получения параметров среды. Кроме того, OpenMP включает API-функции для поддержки некоторых типов синхронизации.

Прагмы синхронизации

`#pragma omp single` – исполняет следующую команду только с помощью одного (случайного) потока

`#pragma omp barrier` – удерживает потоки в этом месте, пока все потоки не дойдут до него

`#pragma omp atomic` – атомарно исполняет следующую операцию доступа к памяти (т.е. без прерывания от других ветвей)

`#pragma omp critical [имя потока]` – позволяет только одному потоку перейти к исполнению следующей команды

Критическая секция

```
#pragma omp parallel for schedule(static)
    for (int i = 0; i < N; i++)
        PerformSomeComputation(i);
  // внутри этой функции  плохой  код
```

ОШИБКА!

Функция *PerformSomeComputation* изменяет значение глобальной переменной – гонка данных

```
    int global = 0;
    void PerformSomeComputation(int i) {
        global += i;
    }
```

Критическая секция

Избежать ситуацию возникновения гонки за ресурсами позволяет использование критических секций:

```
void PerformSomeComputation(int i)  {
    #pragma omp critical
    {
        global += i;
    }
}
```

Критическая секция

#pragma omp critical позволяет только одному потоку выполнить операцию даже внутри параллельного фрагмента

```
int a[MAXN], sum=0;
#pragma omp parallel for
for (int i = 0; i < N; i++)
  {
        #pragma omp critical
    sum +- a[i];
  }
```

Библиотека функций

void omp_set_num_threads(int numThreads)

Позволяет назначить максимальное число потоков для использования в следующей параллельной области (если это число разрешено менять динамически).
Вызывается из последовательной области программы

Библиотека функций

int omp_get_max_threads()

Возвращает максимальное число потоков

int omp_get_num_threads()

Возвращает фактическое число потоков в параллельной области программы

Библиотека функций

int omp_get_thread_num()

Возвращает номер потока

int omp_get_num_procs()

Возвращает число процессоров, доступных приложению

Библиотека функций

int omp_in_parallel()

Возвращает true, если вызвана из параллельной области программы

Библиотека функций

Блокировки

```
omp_lock_t    myLock;
omp_init_lock(  &myLock  );

omp_set_lock(  &myLock );
omp_unset_lock(  &myLock  );

omp_test_lock (  &myLock  );
   ...
```

Правильный код блокировки

```
omp_lock_t    myLock;
omp_init_lock(&myLock);
#pragma omp parallel sections
 {
  #pragma omp section
   {        ...
      omp_set_lock(&myLock);          ...
      omp_unset_lock(&myLock);          ...
   }
  #pragma omp section
   {        ...
      omp_set_lock(&myLock);          ...
      omp_unset_lock(&myLock);          ...
   }
 }
```

Лабораторная работа № 3

Реализовать задание к работе № 2 средствами OpenMP