

МО ВВС ИВМиМГ СО РАН

Программирование многоядерных архитектур

**(слайды для лекции
2013/04/20)**

Киреев С.Е., Маркова В.П.,
Остапкевич М.Б., Перепелкин В.
2013
А.

План презентации

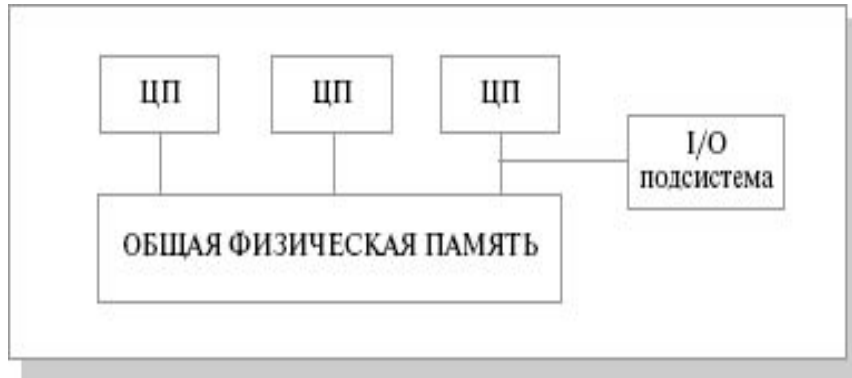
- кратко о параллельных ЭВМ;
- введение в многопоточность;
- интерфейсы работы с потоками;
- OpenMP:
 - организация многопоточности,
 - синхронизация,
 - что замедляет вычисления;
- цель работы, задание

Кратко о параллельных ЭВМ

ОСНОВНЫЕ КЛАССЫ параллельных ЭВМ

SMP

*Sequent (1991), HP 9000 V-class
Tilera (2010)*



NUMA

SGI Origin2000

PVP


*CRAY-1, CRAY X1,
Fujitsu VPP*

COW

Beowulf

MPP

*IBM RS/6000 SP2
CRAY T3E*



NOW

GPGPU

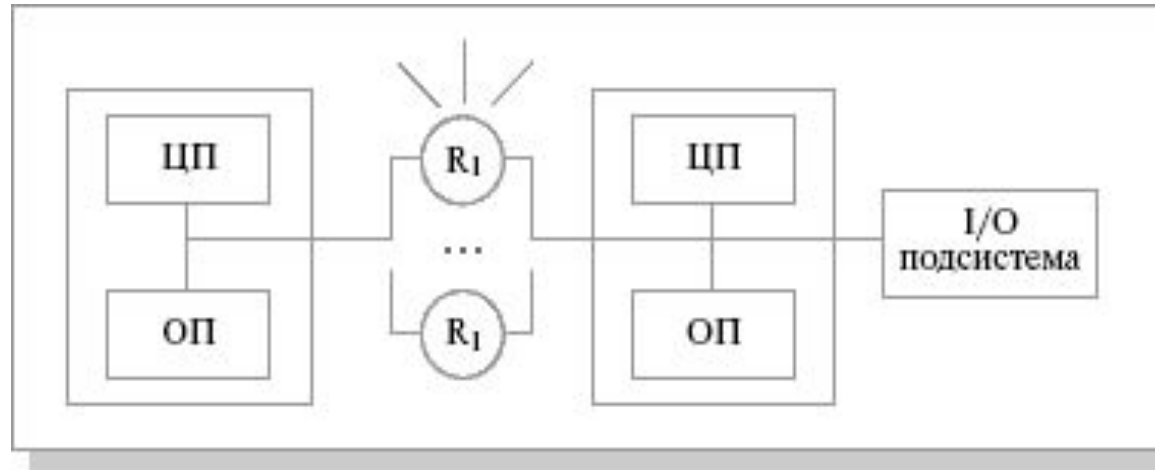
NVIDIA, ATI, S3

FPGA

Xilinx, Altera

Основные виды параллельных ЭВМ

- **Мультикомпьютеры**



- **Мультипроцессоры**

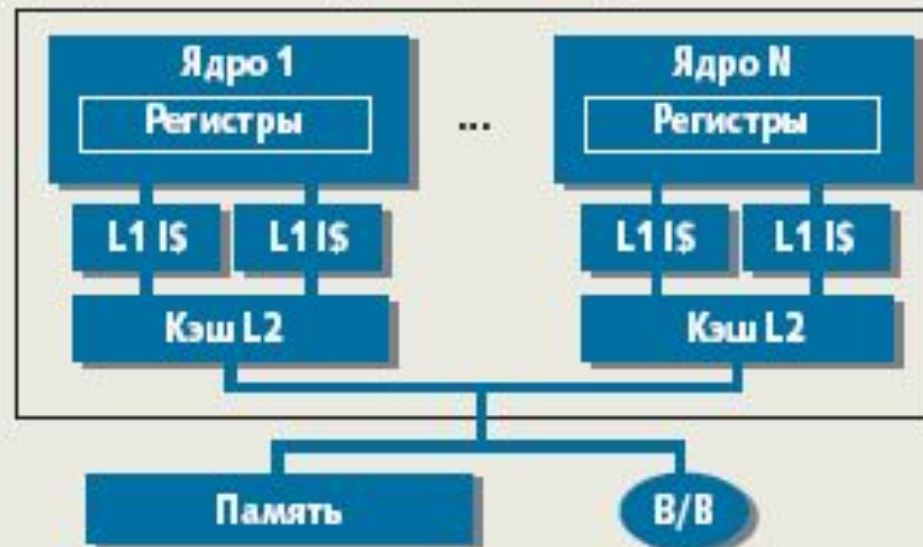


Многоядерность

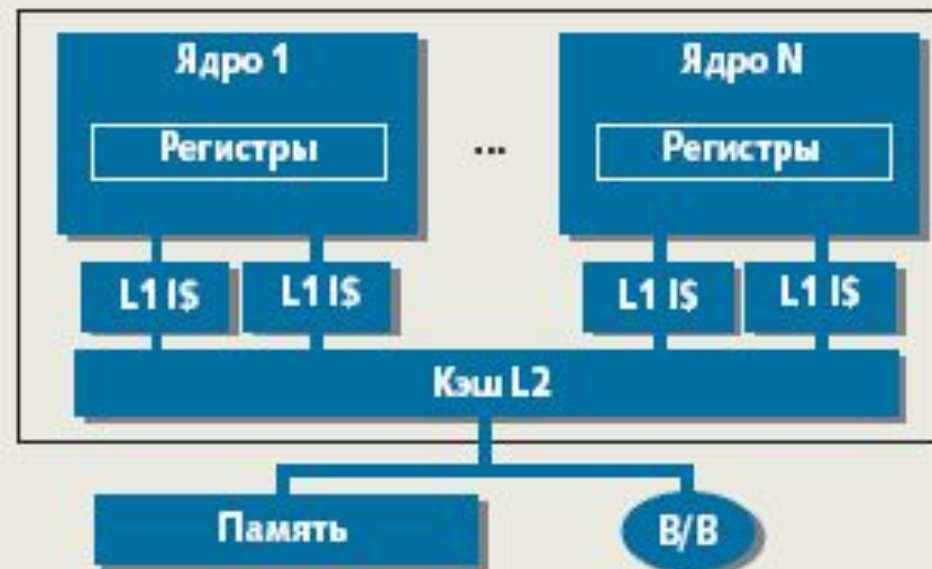
а) Традиционный процессор



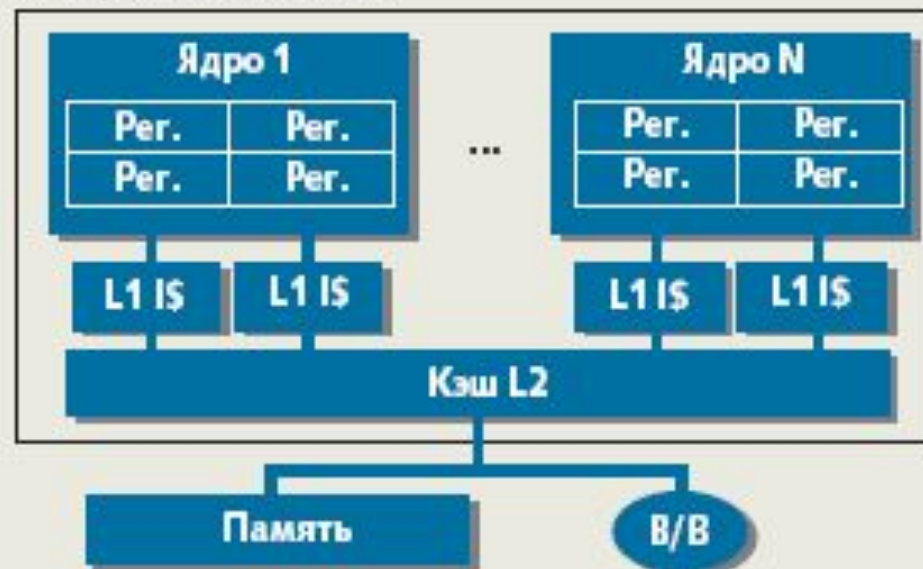
б) Простая многоядерная архитектура



в) Многоядерная архитектура с общей кэш-памятью



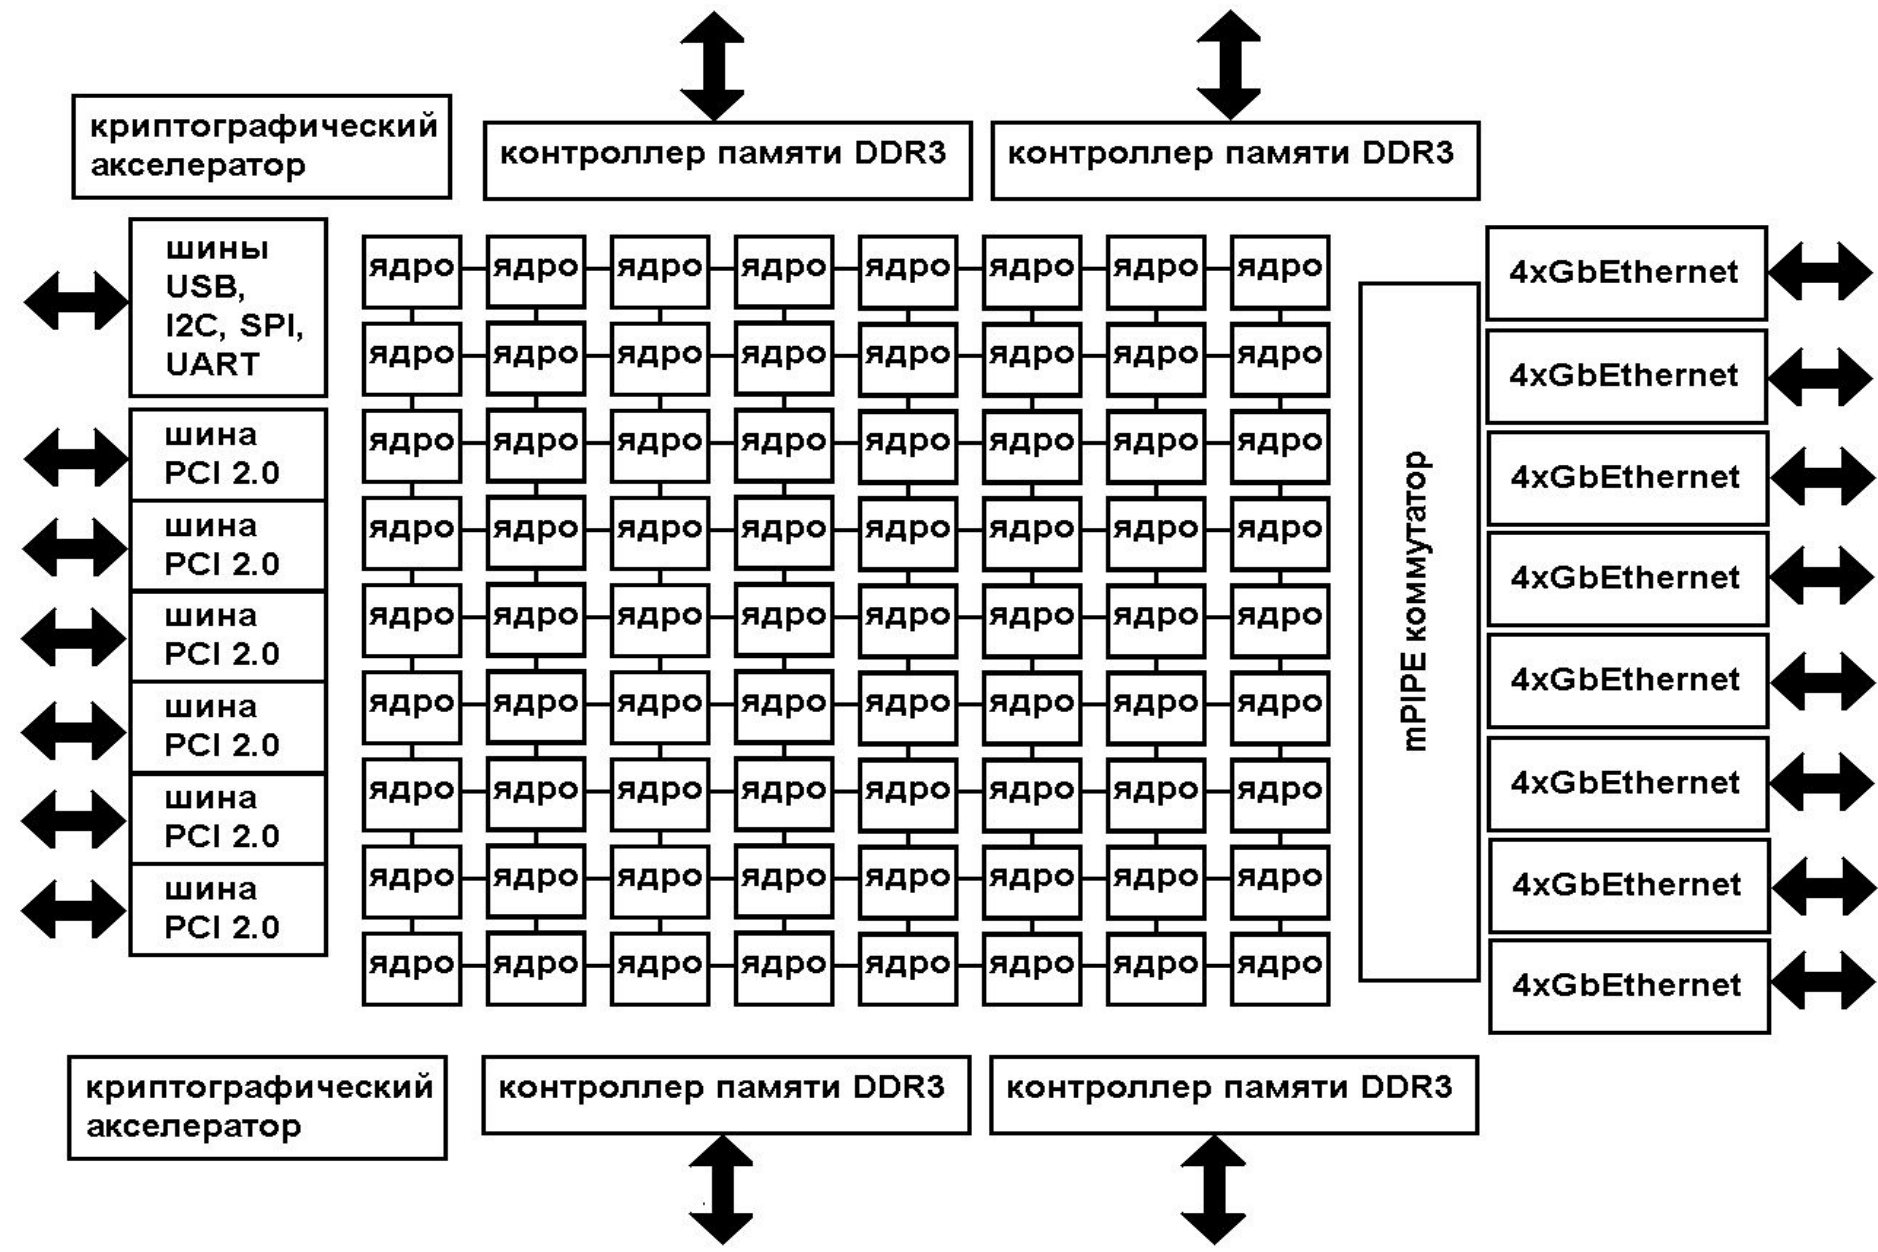
г) Многопоточная многоядерная архитектура с общей кэш-памятью



Примеры многоядерных процессоров

- Intel XEON Phi 60 ядер
- Tiler TILE-Gx8072 72 ядра
- GreenArrays GA144A12 144 ядра

Процессор Tiler TILE-Gx8072



ВВЕДЕНИЕ В МНОГОПОТОЧНОСТЬ

- процесс,**
- ПОТОК,**
- многозадачность,**
- многопоточная программа.**

Процесс

Процесс - экземпляр запущенной на исполнение программы.

Имеет собственные:

- состояние, код возврата, переменные окружения, идентификаторы себя, владельца и родителя, приоритет;
- отдельное адресное пространство/виртуальная память и/или физическая память;
- данные в памяти; исполняемый код в памяти;
- один или несколько потоков исполнения

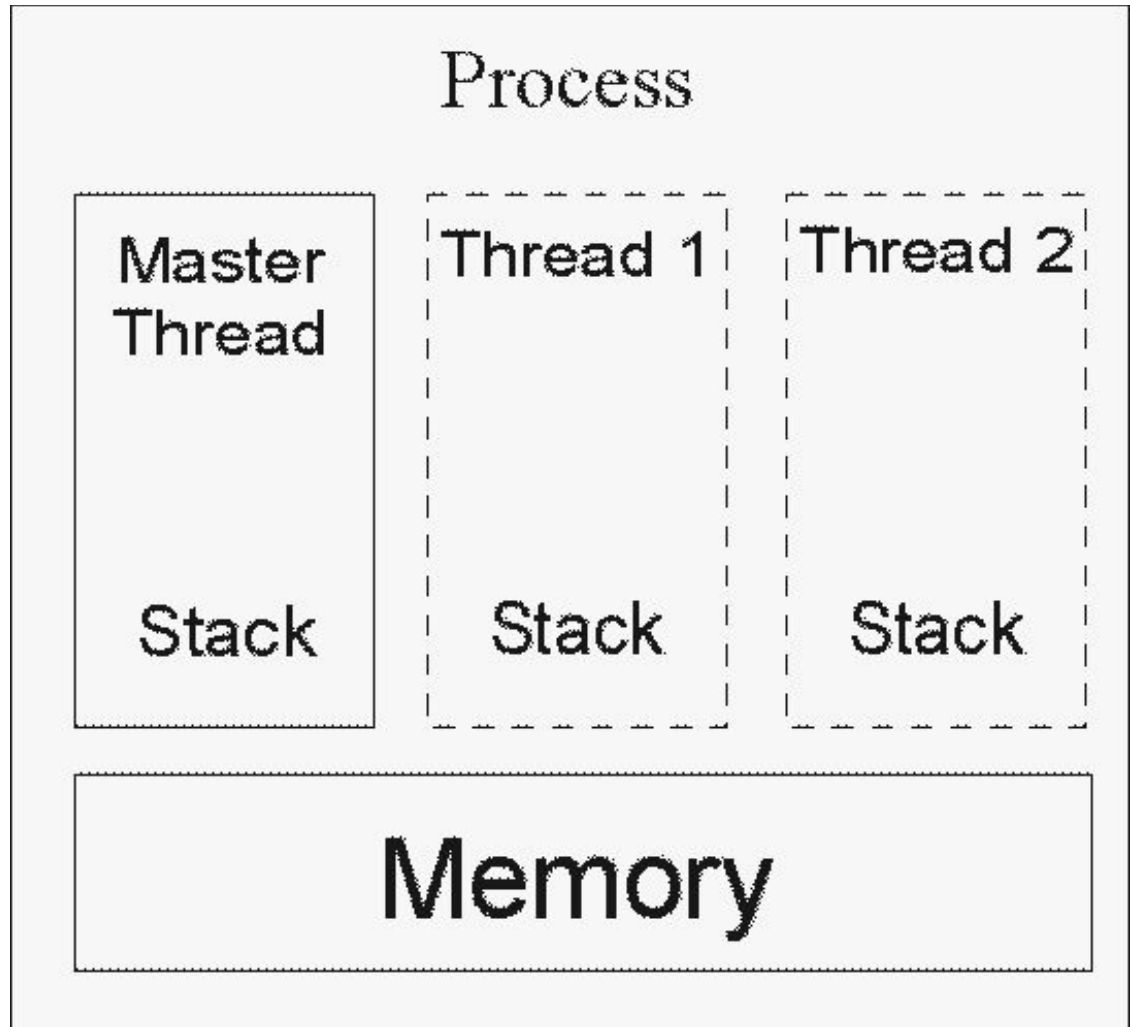
Поток

Разделяет общие:

- адресное пространство/ память,
- данные в памяти,
- исполняемый код.

Имеет собственные:

- ID, приоритет;
- Регистры;
- поток команд,



Многозадачность

Формы многозадачности:

- **разделение времени;**
- **параллельное исполнение.**

**Виды планирования
многозадачности:**

- **вытесняющая (Win32, Win64, Linux);**
- **кооперативная (Win16).**

Интерфейсы по работе с потоками

Интерфейс	Windows	Windows+ MinGW, Cygwin	UNIX
Win32 Threads	+	+	
POSIX Threads		+	+
OpenMP	+	+	+

OpenMP

- **организация многопоточности;**
- **синхронизация;**
- **что замедляет вычисления.**

Что такое OpenMP?

Стандарт OpenMP определяет:

- интерфейс (API);**
- набор прагм компилятора;**
- переменные окружения**

для построения многопоточных приложений на мультипроцессорных системах в модели общей памяти.

Архитектура OpenMP

Конечный Пользователь

Приложение

директивы,
компилятор

OpenMP библиотека

переменные
окружения

OpenMP Runtime библиотека

Поддержка потоков и разделяемой памяти в ОС

Proc1

Proc₂

Proc₃


...

ProcN

Разделяемое адресное пространство

МОДЕЛЬ ИСПОЛНЕНИЯ

Fork-join



OpenMP программа 1

Напишем многопоточную программу, в которой:

- каждый поток печатает свой номер,**
- один поток печатает количество запущенных потоков в**

Шаги создания OpenMP программы

1. Подключение заголовочного файла:

```
#include <omp.h>
```

2. Создание параллельно исполняемого блока в функции main():

```
void main(){  
    #pragma omp parallel  
    {  
    }  
}
```



Шаги создания OpenMP программы

3. Декларация переменной, собственную копию которой имеет каждый поток:

```
#include <omp.h>
```

```
void main(){
```

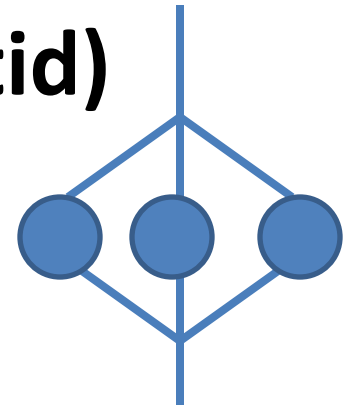
```
    int tid;
```

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

```
    {
```

```
    }
```


```
}
```



Шаги создания OpenMP программы

3. Получение и печать номера потока:

```
void main(){  
    int tid;  
    #pragma omp parallel private(tid)  
    {  
        tid = omp_get_thread_num();  
        printf("thread num=%d\n", tid);  
    }  
}
```




Шаги создания OpenMP

программы

4. Декларация переменной, общей для всех потоков.

5. Получение и печать количества потоков:

```
void main(){  
    int tid, tnum;  
    #pragma omp parallel private(tid)  
    { tid = omp_get_thread_num();  
      printf("thread num=%d\n", tid);  
      tnum= omp_get_num_threads();  
      printf("number of threads=%d\n", tnum);  
    }  
}
```



Шаги создания OpenMP

программы

6. Исполнение кода только одним потоком:

```
#pragma omp parallel private(tid)
{
    tid = omp_get_thread_num();
    printf("thread num=%d\n", tid);
    if(tid == 0){
        tnum= omp_get_num_threads();
        printf("number of threads=%d\n", tnum);
    }
}
```

Шаги создания OpenMP

программы

7. Компиляция OpenMP программы:

В Windows + Microsoft Visual C++:

```
cl.exe myprog.c /openmp
```

**В UNIX, Linux, Windows+MinGW,
Windows+CygWin**

```
gcc -o myprog myprog.c -fopenmp
```


OpenMP программа 2

Напишем многопоточную программу, для поэлементного суммирования двух векторов способами:

- 1) используя конструкцию распределения работы,**
- 2) используя секции.**

OpenMP программа 2

1. Пишем общую часть

```
#include <omp.h>  
void main ()  
{ int i;  
    float a[N], b[N], c[N];  
    for (i=0; i < N; i++)  
        a[i] = b[i] = 1.0;  
}
```

Способ 1. Распределение работы между потоками

2. Добавляем параллельную часть

```
#pragma omp parallel shared(a,b,c) private(i)
{
    #pragma omp for schedule(dynamic, 100) nowait
    for (i=0; i < N; i++)
        c[i] = a[i] + b[i];
}
```

Ограничения в for

- число итераций известно до входа в цикл,
- итерации независимы
- Индекс меняется только следующим образом:
 $i++$, $i--$, $i += c$, $i -= c$.

СПОСОБ 2. С ИСПОЛЬЗОВАНИЕМ СЕКЦИЙ

2. Добавляем параллельную часть

```
#pragma omp parallel shared(a,b,c) private(i)
{
#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];
}
}
```

OpenMP программа 3

**Напишем многопоточную
программу вычисления
скалярного произведения
векторов.**

OpenMP программа 3

1. Напишем последовательную часть.

```
#include <omp.h>
```

```
#define N 1000
```

```
void main()
```

```
{ int i;
```

```
float a[N], b[N], res;
```

```
for (i=0; i < N; i++){a[i] = 2.0f; b[i] = 1.0f;}
```

```
res = 0.0f;
```

```
}
```

OpenMP программа 3

1. Напишем параллельную часть.

```
#pragma omp parallel for \  
    default(shared) private(i) \  
    schedule(static, 100) reduction(+:res)  
for(i = 0; i < N; i++)  
    res = res + (a[i] * b[i]);
```


OpenMP программа 4

Напишем многопоточную программу, для увеличения счетчика на единицу:

1) наивно;

2) с синхронизацией.

Вариант 1. Наивный

```
#include <omp.h>
void main(){
    int x; x = 0;
    #pragma omp parallel for shared(x)
    for(int i = 0; i < 1000000; i++){
        x = x + 1;
    }
    printf("x=%d\n", x);
}
```

Вариант 1. Наивный

\$./plus1

x=977177

\$./plus1

x=975883

\$./plus1

x=980608

\$./plus1

x=979246

Получился неверный результат.

Вариант 1. Наивный

Поток 1	Поток 2
Получить X.	
	Получить X.
	Добавить 1.
	Записать в X.
Добавить 1.	
Записать в X.	

Вариант 2. С

Синхронизацией

```
#include <omp.h>
```

```
void main()
```

```
{ int x;
```

```
  x = 0;
```

```
  #pragma omp parallel for shared(x)
```

```
  for(int i = 0; i < 1000000; i++){
```

```
    #pragma omp critical
```

```
    x = x + 1;
```

```
  }
```

```
  printf("x=%d", x)
```

```
}
```

Вариант 2. С синхронизацией

\$./plus2

x=1000000

Вариант 2. С синхронизацией

Поток 1	Поток 2
Получить X.	
Добавить 1.	
Записать в X.	
	Получить X.
	Добавить 1.
	Записать в X.

Что замедляет вычисления?

- избыточное число порождений потока -> если можно, выносим параллельный блок из цикла;
- одновременный доступ двух потоков к одному участку памяти;
- излишняя синхронизация.

Цель работы

- **Написание многопоточного приложения с использованием интерфейса OpenMP.**

Задание

В соответствии с вариантом задания реализовать алгоритм с использованием интерфейса OpenMP.

Варианты:

- 1) скалярное произведение двух векторов (20 баллов),**
- 2) умножение матрицы на вектор (22 балла),**
- 3) Умножение матрицы на матрицу (25 баллов),**
- 4) Решение системы линейных алгебраических уравнений методом Гаусса (30 баллов).**