Лекция 5
Стандарт OpenMP

Курносов Михаил Георгиевич

E-mail: mkurnosov@gmail.com
WWW: www.mkurnosov.net

Курс «Параллельное программирование»
Сибирский государственный университет телекоммуникаций и информатики (г. Новосибирск)
Осенний семестр, 2018

Многопроцессорные системы с общей памятью

SMP-системы

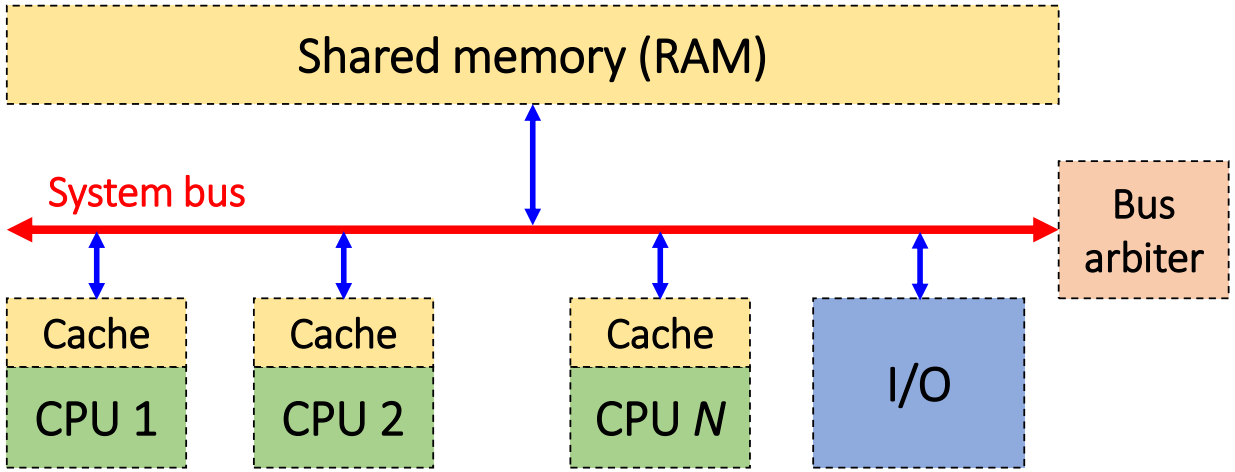

- **Процессоры SMP-системы** имеют одинаковое время доступа к разделяемой памяти: симметричный, однородный доступ к памяти – Uniform Memory Access (UMA)
- **Системная шина** (system bus, crossbar) – узкое место, ограничивающее производительность вычислительного узла (процессоры конкурируют за доступ к ней)
- **Проблемы:** низкая масштабируемость, обеспечение когерентности (согласованности) кеш-памяти процессоров и разделяемой памяти

Многопроцессорные системы с общей памятью

NUMA-системы

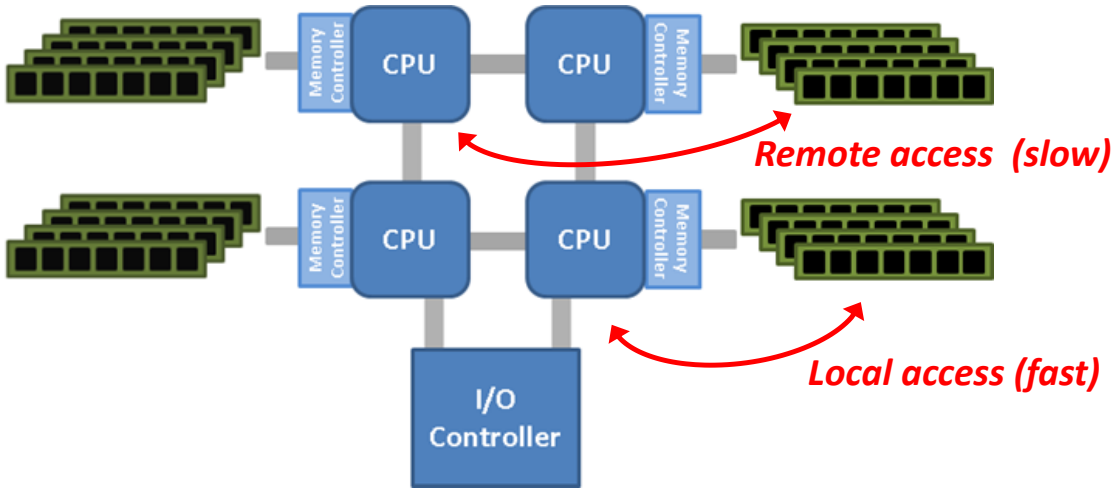

- **NUMA** (Non-Uniform Memory Architecture) – многопроцессорная вычислительная система с неоднородным доступом к разделяемой памяти
- **Процессоры сгруппированы в NUMA-узлы** со своей локальной памятью (NUMA nodes)
- **Разное время доступа** к локальной памяти NUMA-узла (NUMA-node) и памяти другого узла
- Большая масштабируемость по сравнению с SMP-системами
- **Проблемы**: обеспечение когерентности кеш-памяти процессоров

Процессы и потоки


```
// Uninitialized data (BSS)
int sum[100]; // BSS

// Initialized data (Data)
float grid[100][100] = {1.0};

int main()
{
    // Local variable (stack)
    double s = 0.0;

    // Allocate from the heap
    float *x = malloc(1000);
    // ...
    free(x);
}
```

Процессы и потоки


```
// Uninitialized data (BSS)
int sum[100]; // BSS

// Initialized data (Data)
float grid[100][100] = {1.0};

int main()
{
    // Local variable (stack)
    double s = 0.0;

    // Allocate from the heap
    float *x = malloc(1000);
    // ...
    free(x);
}
```

Средства многопоточного программирования

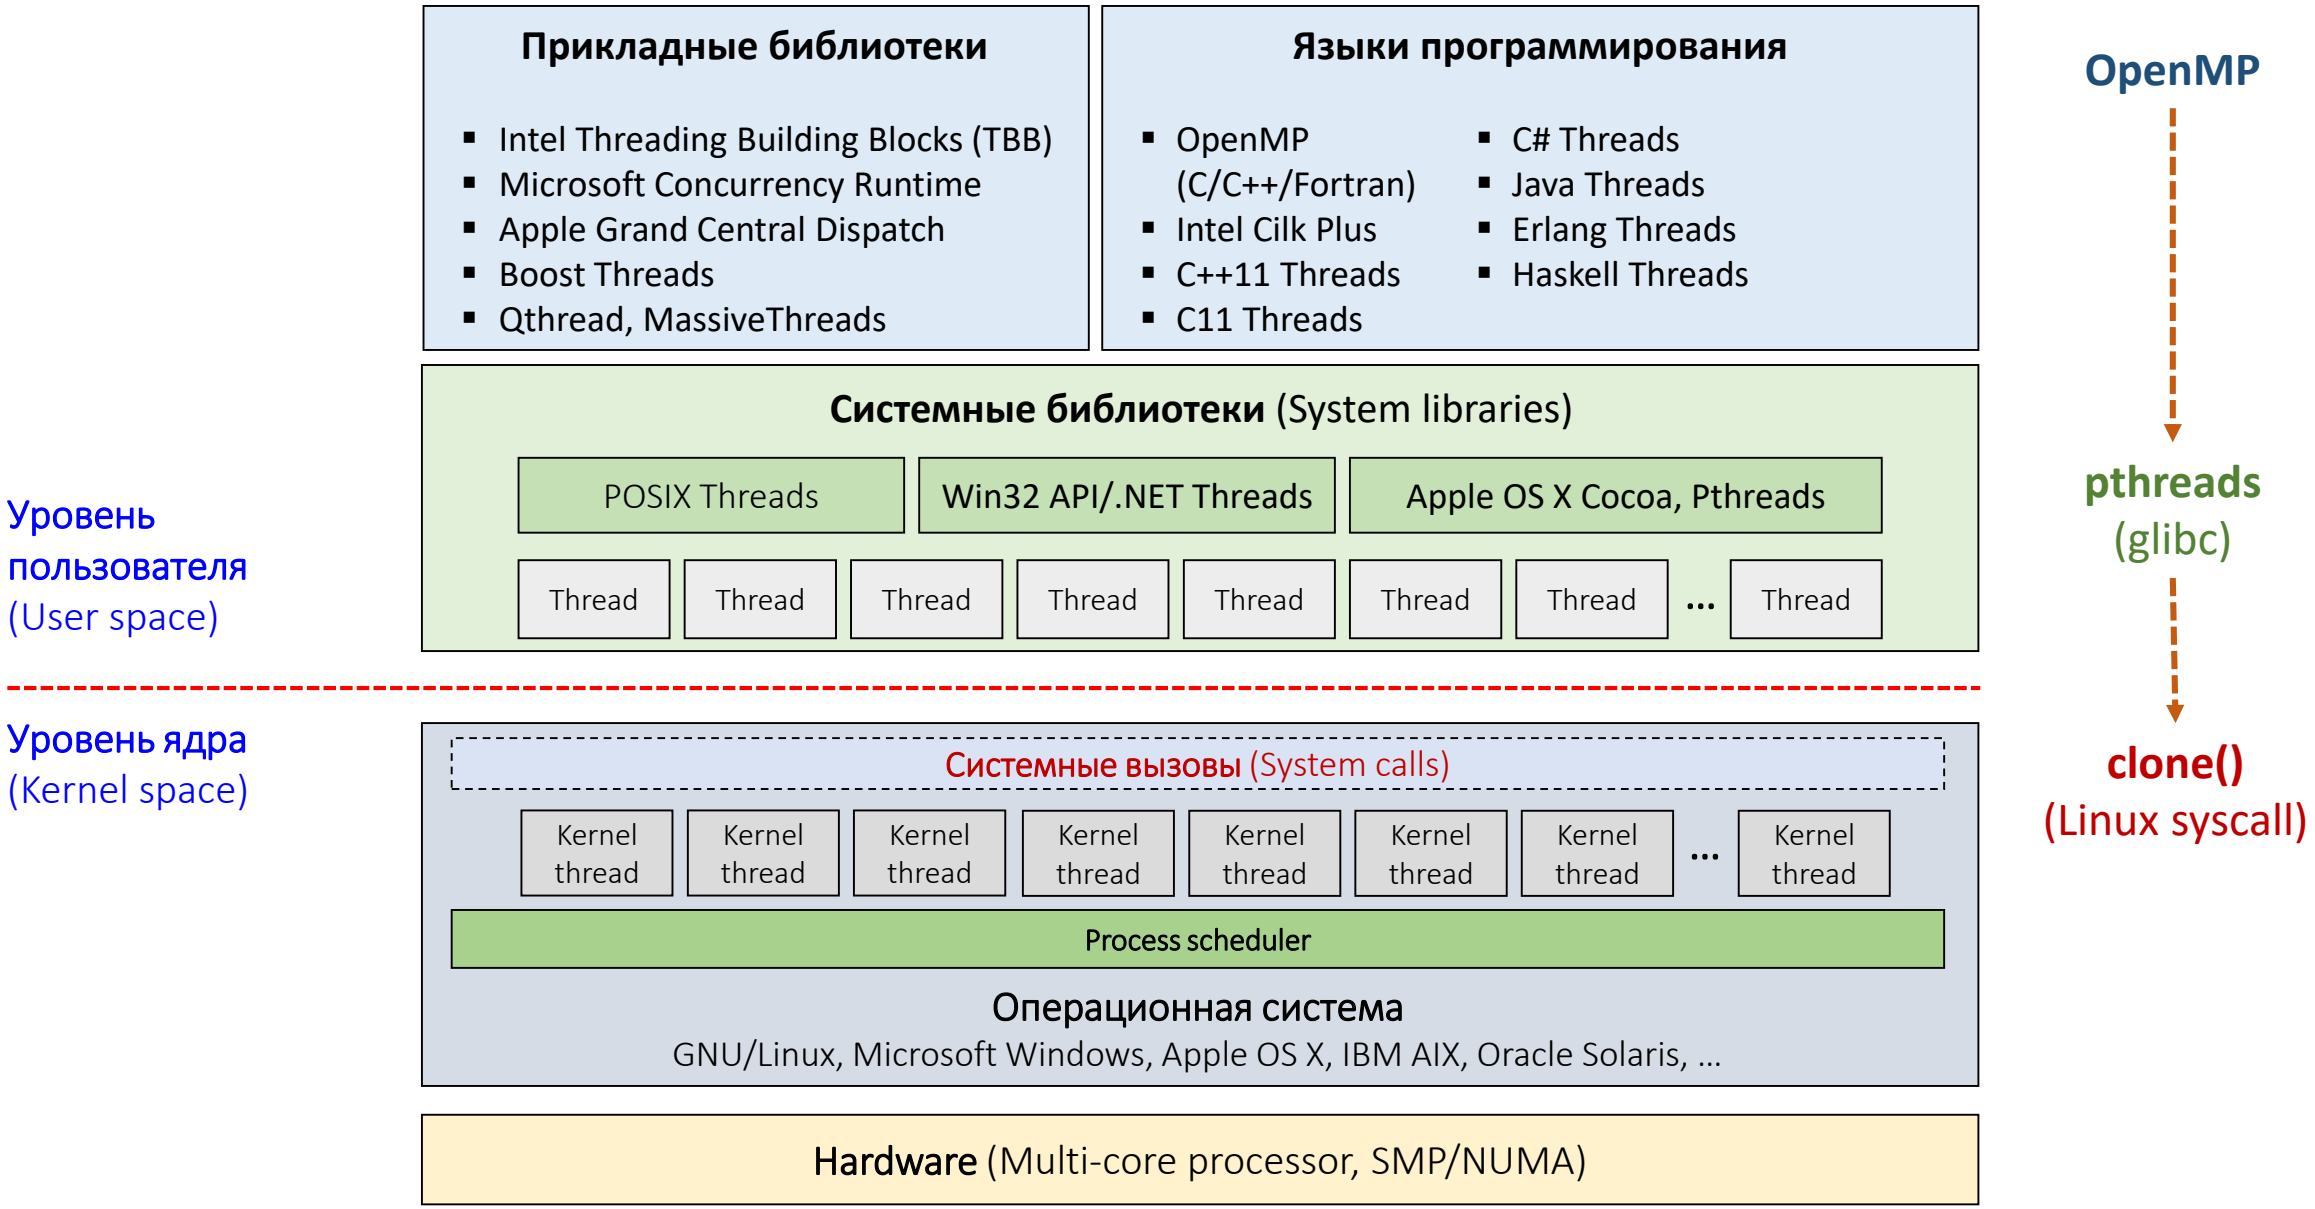

Стандарт OpenMP

- **OpenMP (Open Multi-Processing)** – стандарт, определяющий набор директив компилятора, библиотечных процедур и переменных среды окружения для создания многопоточных программ

- Разрабатывается в рамках OpenMP Architecture Review Board с 1997 года
  - OpenMP 2.5 (2005), OpenMP 3.0 (2008), OpenMP 3.1 (2011), **OpenMP 4.0 (2013)**
  - http://www.openmp.org
  - http://www.openmp.org/mp-documents/OpenMP4.0.0.pdf

- Требуется поддержка со стороны компилятора

Поддержка компиляторами

Compiler	Information
GNU GCC	Option: –fopenmp gcc 4.2 – OpenMP 2.5, gcc 4.4 – OpenMP 3.0, gcc 4.7 – OpenMP 3.1 gcc 4.9 – OpenMP 4.0
Clang (LLVM)	OpenMP 3.1 clang + Intel OpenMP RTL http://clang-omp.github.io/
Intel C/C++, Fortran	OpenMP 4.0 Option: –Qopenmp, –openmp
Oracle Solaris Studio C/C++/Fortran	OpenMP 4.0 Option: –xopenmp
Microsoft Visual Studio C++	Option: /openmp OpenMP 2.0 only
Other compilers: IBM XL, PathScale, PGI, Absoft Pro, …	

Модель выполнения OpenMP-программы

- **Динамическое управление потоками в модели Fork-Join**:
  - ✓ Fork – порождение нового потока
  - ✓ Join – ожидание завершения потока (объединение потоков управления)
- OpenMP-программа – совокупность последовательных участков кода (serial code) и параллельных регионов (parallel region)
- Каждый поток имеет логический номер: 0, 1, 2, …
- Главный поток (master) имеет номер 0
- Параллельные регионы могут быть вложенными

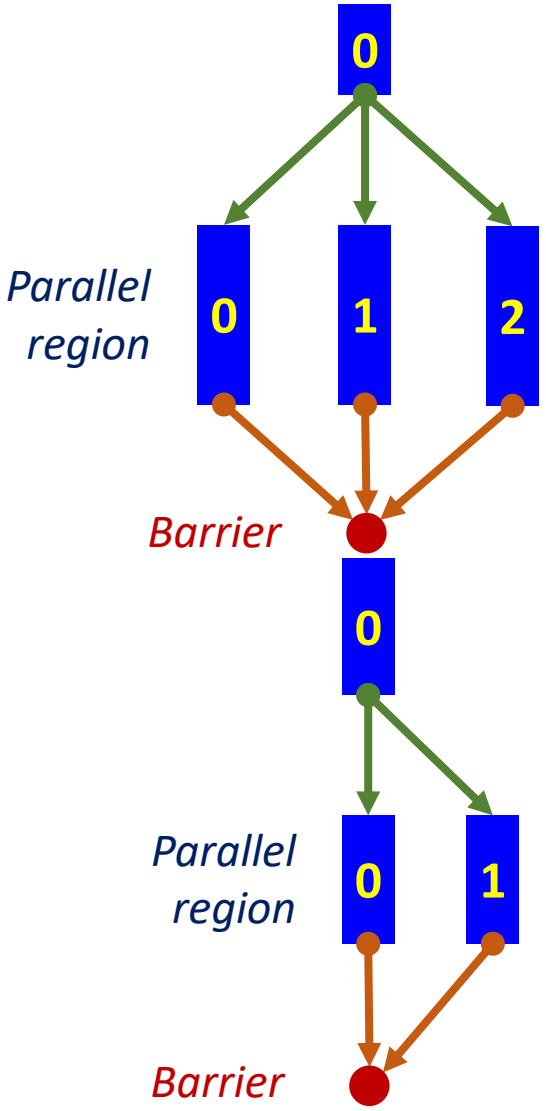

Hello, World

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

int main(int argc, char **argv)
{
    #pragma omp parallel    /* <-- Fork */
    {
        printf("Hello, multithreaded world: thread %d of %d\n",
               omp_get_thread_num(), omp_get_num_threads());

    }                       /* <-- Barrier & join */

   return 0;
}
```

Компиляция и запуск OpenMP-программы

```
$ gcc –fopenmp –o hello ./hello.c

$ ./hello
Hello, multithreaded world: thread 0 of 4
Hello, multithreaded world: thread 1 of 4
Hello, multithreaded world: thread 3 of 4
Hello, multithreaded world: thread 2 of 4
```

- По умолчанию количество потоков в параллельном регионе равно числу логических процессоров в системе
- Порядок выполнения потоков заранее неизвестен – определяется планировщиком операционной системы

Указание числа потоков в параллельных регионах

```
$ export OMP_NUM_THREADS=8

$ ./hello
Hello, multithreaded world: thread 1 of 8
Hello, multithreaded world: thread 2 of 8
Hello, multithreaded world: thread 3 of 8
Hello, multithreaded world: thread 0 of 8
Hello, multithreaded world: thread 4 of 8
Hello, multithreaded world: thread 5 of 8
Hello, multithreaded world: thread 6 of 8
Hello, multithreaded world: thread 7 of 8
```

Задание числа потоков в параллельном регионе

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

int main(int argc, char **argv)
{
    #pragma omp parallel num_threads(6)
    {
        printf("Hello, multithreaded world: thread %d of %d\n",
               omp_get_thread_num(), omp_get_num_threads());
    }

    return 0;
}
```

Задание числа потоков в параллельном регионе

```
$ export OMP_NUM_THREADS=8

$ ./hello
Hello, multithreaded world: thread 2 of 6
Hello, multithreaded world: thread 3 of 6
Hello, multithreaded world: thread 1 of 6
Hello, multithreaded world: thread 0 of 6
Hello, multithreaded world: thread 4 of 6
Hello, multithreaded world: thread 5 of 6
```

- Директива num_threads имеет приоритет над значением переменной среды окружения OMP_NUM_THREADS

Список потоков процесса

```c
#include <stdio.h>
#include <omp.h>
#include <time.h>

int main(int argc, char **argv)
{
    #pragma omp parallel num_threads(6)
    {
        printf("Hello, multithreaded world: thread %d of %d\n",
               omp_get_thread_num(), omp_get_num_threads());

        /* Sleep for 30 seconds */
        nanosleep(&(struct timespec){.tv_sec = 30}, NULL);
    }
    return 0;
}
```

Список потоков процесса

```
$ ./hello &
$ ps -eLo pid,tid,psr,args | grep hello
 6157  6157   0 ./hello
 6157  6158   1 ./hello
 6157  6159   0 ./hello
 6157  6160   1 ./hello
 6157  6161   0 ./hello
 6157  6162   1 ./hello
 6165  6165   2 grep hello
```

- Номер процесса (PID)
- Номер потока (TID)
- Логический процессор (PSR)
- Название исполняемого файла

- Информация о логических процессорах системы:
  - /proc/cpuinfo
  - /sys/devices/system/cpu

Умножение матрицы на вектор (DGEMV)

- Требуется вычислить произведение прямоугольной матрицы ***A*** размера $m \times n$ на вектор-столбец ***B*** размера $m \times 1$ (BLAS Level 2, DGEMV)

$$\boldsymbol{C_{m\times 1} = A_{m\times n} \cdot B_{n\times 1}}$$

$$C = \begin{pmatrix} c_1 \\ c_2 \\ \dots \\ c_m \end{pmatrix} \qquad A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{pmatrix} \qquad B = \begin{pmatrix} b_1 \\ b_2 \\ \dots \\ b_n \end{pmatrix}$$

$$c_i = \sum_{j=1}^{n} a_{ij} \cdot b_j\,, \qquad i = 1,2,\dots,m.$$

DGEMV: последовательная версия

```
/*
 * matrix_vector_product: Compute matrix-vector product c[m] = a[m][n] * b[n]
 */
void matrix_vector_product(double *a, double *b, double *c, int m, int n)
{
    for (int i = 0; i < m; i++) {
        c[i] = 0.0;
        for (int j = 0; j < n; j++)
            c[i] += a[i * n + j] * b[j];
    }
}
```

$$c_i = \sum_{j=1}^{n} a_{ij} \cdot b_j , \qquad i = 1,2, \dots , m.$$

DGEMV: последовательная версия

```
void run_serial()
{
    double *a, *b, *c;

    a = xmalloc(sizeof(*a) * m * n);
    b = xmalloc(sizeof(*b) * n);
    c = xmalloc(sizeof(*c) * m);

    for (int i = 0; i < m; i++) {
        for (int j = 0; j < n; j++)
            a[i * n + j] = i + j;
    }
    for (int j = 0; j < n; j++)
        b[j] = j;

    double t = wtime();
    matrix_vector_product(a, b, c, m, n);
    t = wtime() - t;

    printf("Elapsed time (serial): %.6f sec.\n", t);
    free(a);
    free(b);
    free(c);
}
```

DGEMV: параллельная версия

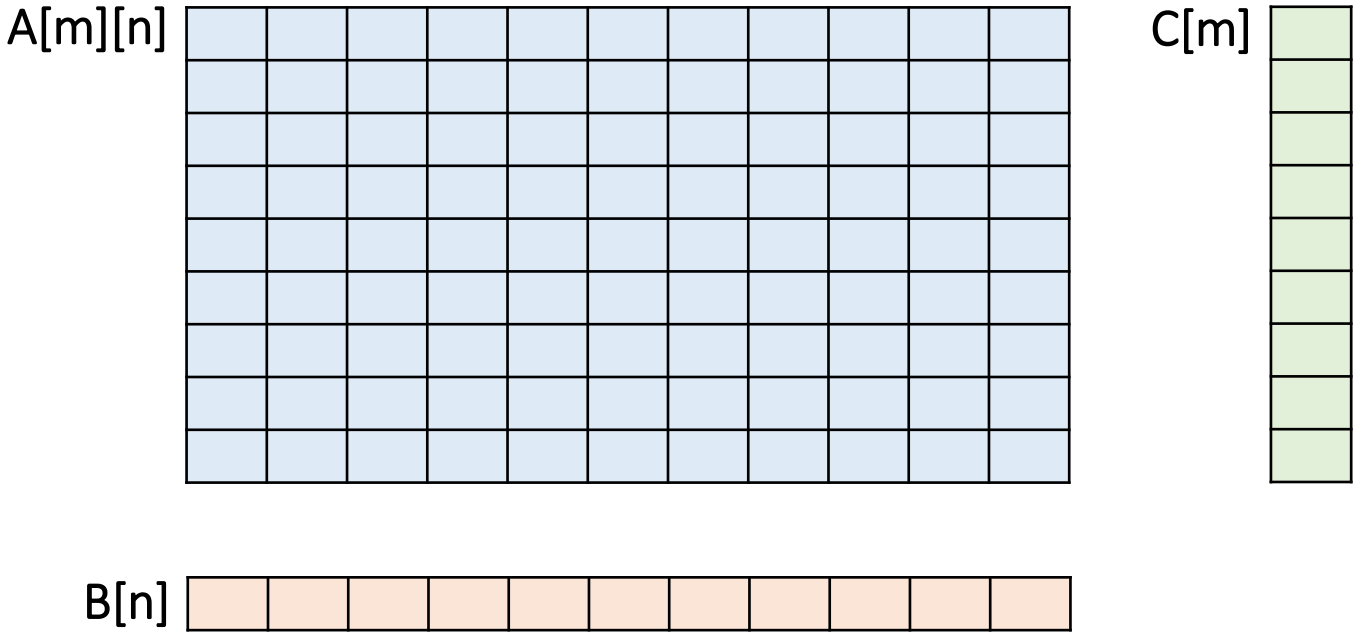


```
for (int i = 0; i < m; i++) {
    c[i] = 0.0;
    for (int j = 0; j < n; j++)
        c[i] += a[i * n + j] * b[j];
}
```

Требования к параллельному алгоритму

- Максимальная загрузка потоков вычислениями
- Минимум совместно используемых ячеек памяти – независимые области данных

DGEMV: параллельная версия

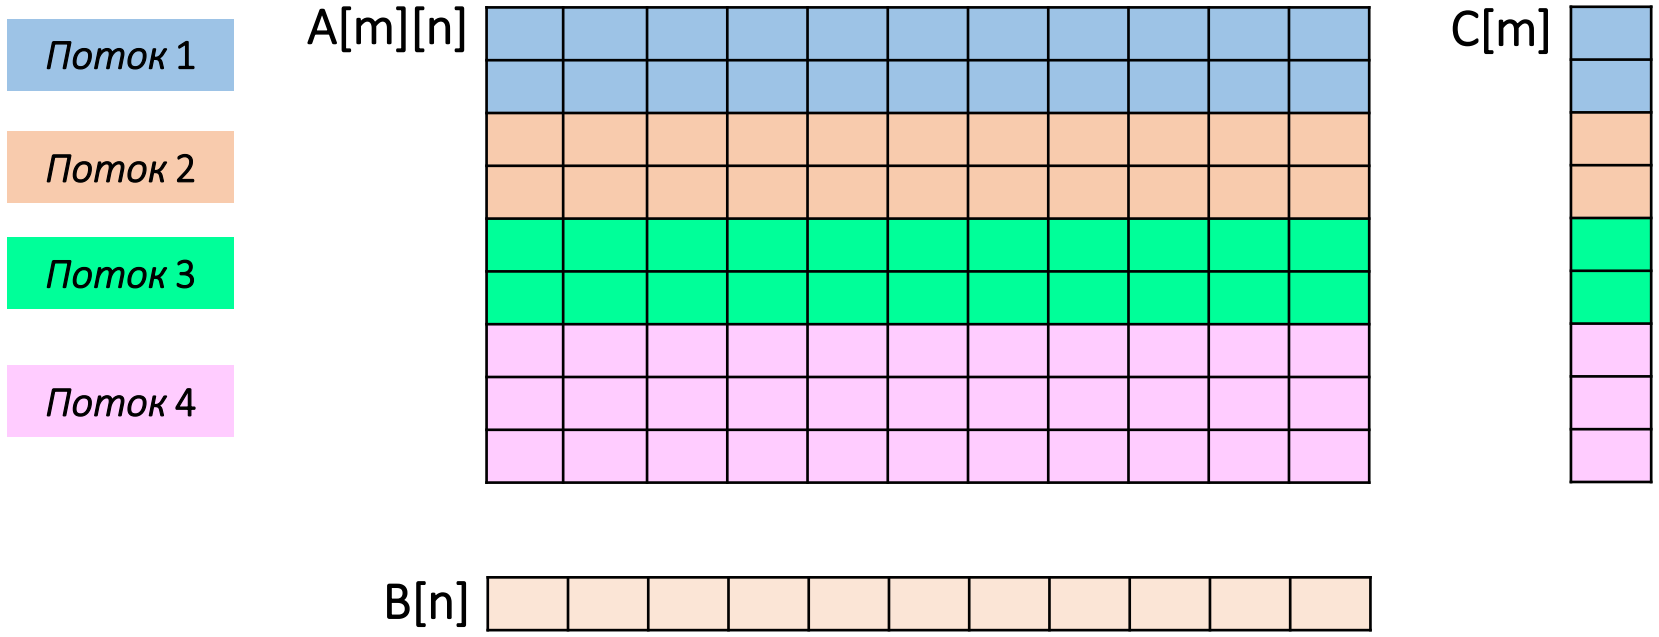


```
for (int i = 0; i < m; i++) {
    c[i] = 0.0;
    for (int j = 0; j < n; j++)
        c[i] += a[i * n + j] * b[j];
}
```

Распараллеливание внешнего цикла

- Каждом потоку выделяется часть строк матрицы *A*

DGEMV: параллельная версия

```
/* matrix_vector_product_omp: Compute matrix-vector product c[m] = a[m][n] * b[n] */
void matrix_vector_product_omp(double *a, double *b, double *c, int m, int n)
{
    #pragma omp parallel
    {
        int nthreads = omp_get_num_threads();
        int threadid = omp_get_thread_num();
        int items_per_thread = m / nthreads;
        int lb = threadid * items_per_thread;
        int ub = (threadid == nthreads - 1) ? (m - 1) : (lb + items_per_thread - 1);

        for (int i = lb; i <= ub; i++) {
            c[i] = 0.0;
            for (int j = 0; j < n; j++)
                c[i] += a[i * n + j] * b[j];
        }
    }
}
```

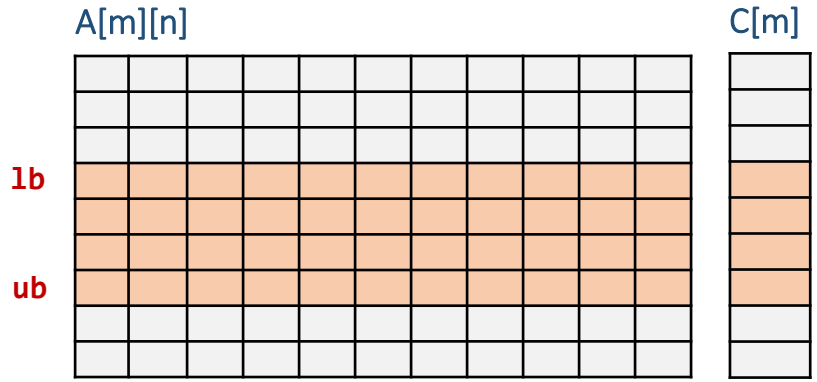

DGEMV: параллельная версия

```
void run_parallel()
{
    double *a, *b, *c;

    // Allocate memory for 2-d array a[m, n]
    a = xmalloc(sizeof(*a) * m * n);
    b = xmalloc(sizeof(*b) * n);
    c = xmalloc(sizeof(*c) * m);

    for (int i = 0; i < m; i++) {
        for (int j = 0; j < n; j++)
            a[i * n + j] = i + j;
    }
    for (int j = 0; j < n; j++)
        b[j] = j;

    double t = wtime();
    matrix_vector_product_omp(a, b, c, m, n);
    t = wtime() - t;

    printf("Elapsed time (parallel): %.6f sec.\n", t);
    free(a);
    free(b);
    free(c);
}
```

DGEMV: параллельная версия

```
int main(int argc, char **argv)
{
    printf("Matrix-vector product (c[m] = a[m, n] * b[n]; m = %d, n = %d)\n", m, n);
    printf("Memory used: %" PRIu64 " MiB\n", ((m * n + m + n) * sizeof(double)) >> 20);

    run_serial();
    run_parallel();

    return 0;
}
```

Анализ эффективности OpenMP-версии

- **Введем обозначения:**
  - $\boldsymbol{T(n)}$ – время выполнения последовательной программы (serial program) при заданном размере *n* входных данных
  - $\boldsymbol{T_p(n,p)}$ – время выполнения параллельной программы (parallel program) на *p* процессорах при заданном размере *n* входных данных

- **Коэффициент $S_p(n)$ ускорения** параллельной программ (Speedup):

$$\boldsymbol{S_p(n) = \frac{T(n)}{T_p(n)}}$$

Во сколько раз параллельная программа выполняется на *p* процессорах быстрее последовательной программы при обработке одних и тех же данных размера *n*

- Как правило

$$S_p(n) \leq p$$

- **Цель распараллеливания –**
  достичь линейного ускорения на наибольшем числе процессоров: $S_p(n) \geq c \cdot p, \quad \text{при } p \to \infty \text{ и } c > 0$

Анализ эффективности OpenMP-версии

M = N	Количество потоков								
	2			4		6		8	
	T_1	T_2	S_2	T_4	S_4	T_6	S_6	T_8	S_8
20 000 (~ 3 GiB)	0.73	0.34	**2.12**	0.24	**3.11**	0.23	**3.14**	0.25	**2.84**
40 000 (~ 12 GiB)	2.98	1.30	**2.29**	0.95	**3.11**	0.91	**3.21**	0.87	**3.38**
49 000 (~ 18 GiB)								1.23	**3.69**

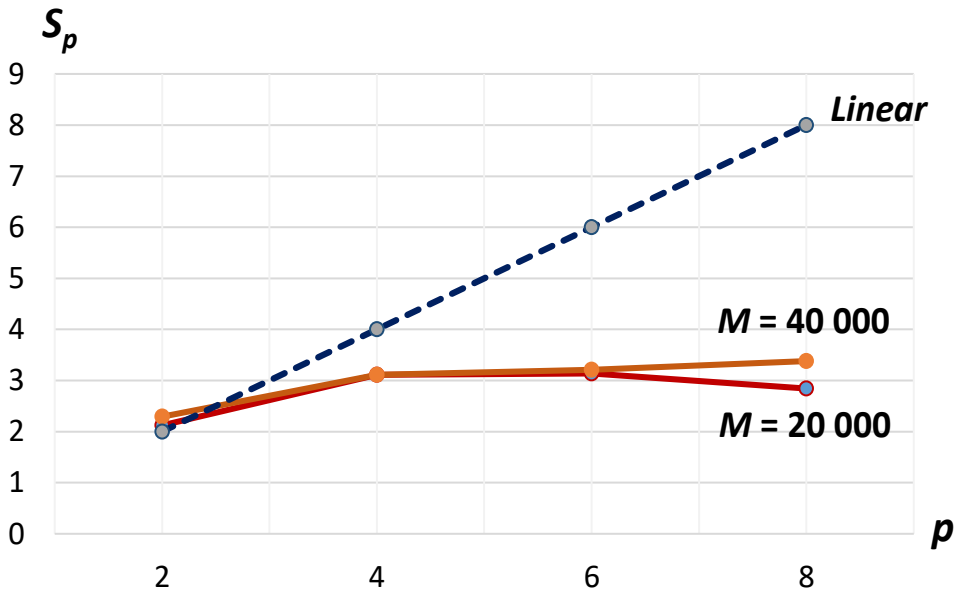

Вычислительный узел кластера Oak (oak.cpct.sibsutis.ru):

- System board: Intel 5520UR
- **8 ядер** – два Intel Quad Xeon E5620 (2.4 GHz)
- **24 GiB RAM** – 6 x 4GB DDR3 1067 MHz
- CentOS 6.5 x86_64, GCC 4.4.7
- Ключи компиляции: -std=c99 -Wall -O2 -fopenmp

Низкая масштабируемость!

Причины ?

DGEMV: конкуренция за доступ к памяти

```
/* matrix_vector_product_omp: Compute matrix-vector product c[m] = a[m][n] * b[n] */
void matrix_vector_product_omp(double *a, double *b, double *c, int m, int n)
{
    #pragma omp parallel
    {
        int nthreads = omp_get_num_threads();
        int threadid = omp_get_thread_num();
        int items_per_thread = m / nthreads;
        int lb = threadid * items_per_thread;
        int ub = (threadid == nthreads - 1) ? (m - 1) : (lb + items_per_thread - 1);

        for (int i = lb; i <= ub; i++) {
            c[i] = 0.0; // Store – запись в память
            for (int j = 0; j < n; j++)
                // Memory ops: Load c[i], Load a[i][j], Load b[j], Store c[i]
                c[i] += a[i * n + j] * b[j];
        }
    }
}
```

- DGEMV – *data intensive application*
- Конкуренция за доступ к контролеру памяти
- ALU ядер загружены незначительно

Конфигурация узла кластера Oak

Вычислительный узел кластера Oak (oak.cpct.sibsutis.ru):

- System board: Intel 5520UR (NUMA-система)
- Процессоры связаны шиной QPI Link: 5.86 GT/s
- 24 GiB RAM – 6 x 4GB DDR3 1067 MHz

```
$ numactl --hardware

available: 2 nodes (0-1)
node 0 cpus: 0 2 4 6
node 0 size: 12224 MB
node 0 free: 11443 MB
node 1 cpus: 1 3 5 7
node 1 size: 12288 MB
node 1 free: 11837 MB
node distances:
node   0   1
  0:  10  21
  1:  21  10
```

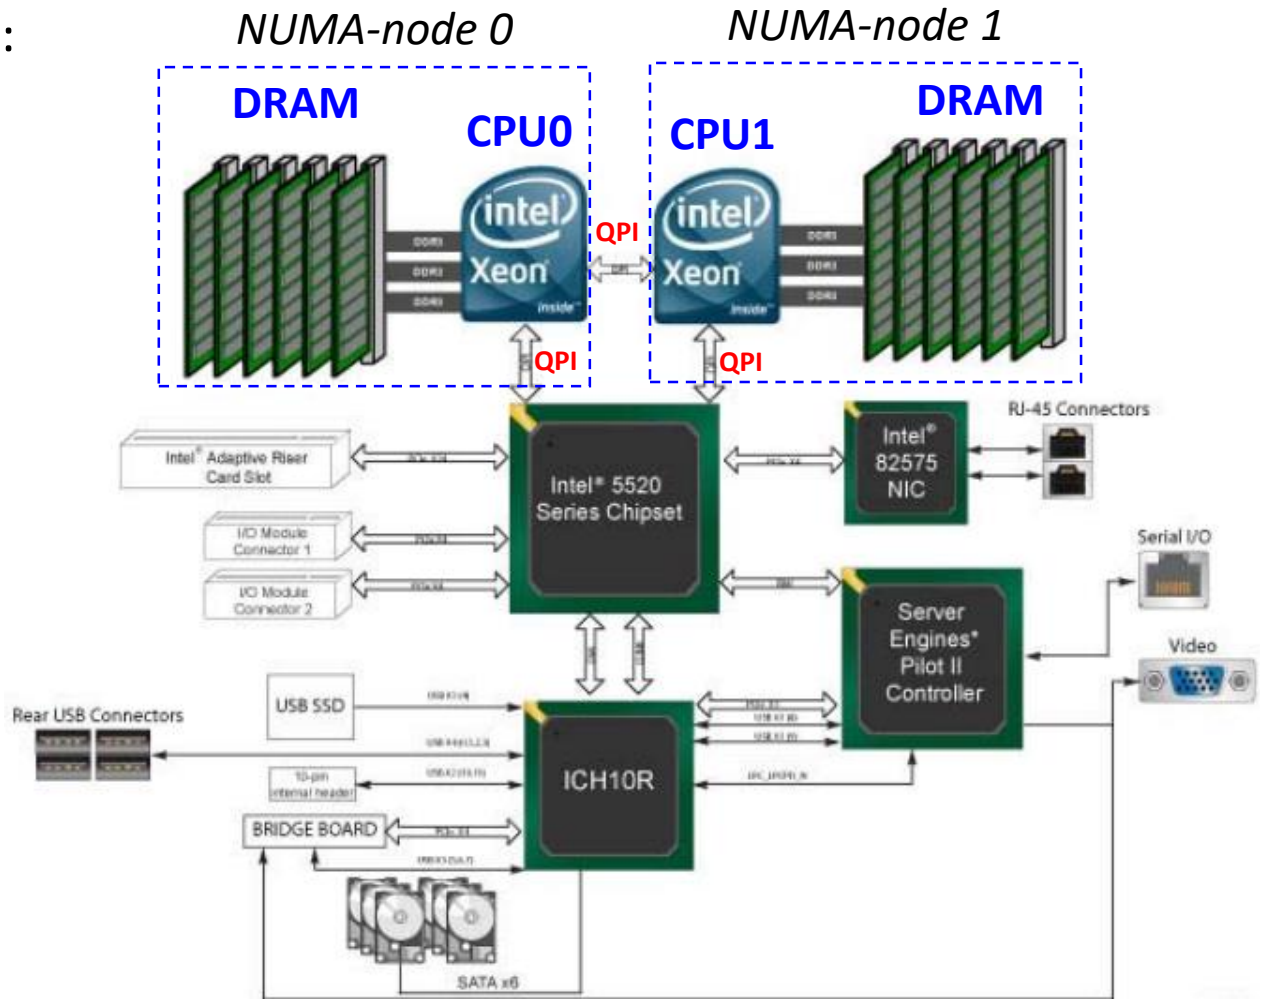

http://download.intel.com/support/motherboards/server/s5520ur/sb/e44031012_s5520ur_s5520urt_tps_r1_9.pdf

Конфигурация узла кластера Oak

Вычислительный узел кластера Oak (oak.cpct.sibsutis.ru):

- System board: Intel 5520UR (NUMA-система)
- Процессоры связаны шиной QPI Link: 5.86 GT/s
- 24 GiB RAM – 6 x 4GB DDR3 1067 MHz

```
$ numactl --hardware

available: 2 nodes (0-1)
node 0 cpus: 0 2 4 6
node 0 size: 12224 MB
node 0 free: 11443 MB
node 1 cpus: 1 3 5 7
node 1 size: 12288 MB
node 1 free: 11837 MB
node distances:
node   0   1
  0:  10  21
  1:  21  10
```

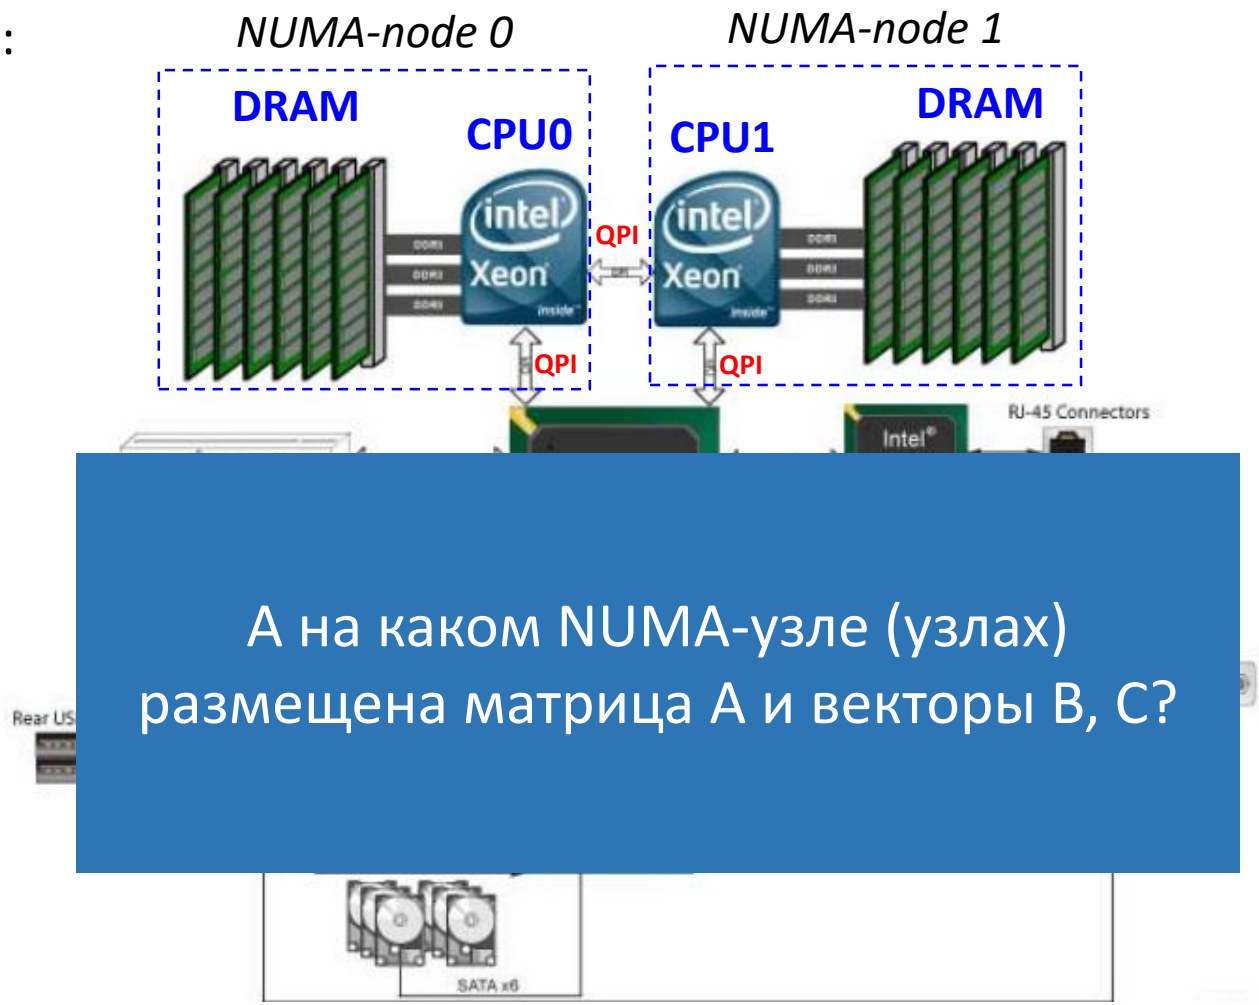

А на каком NUMA-узле (узлах) размещена матрица A и векторы B, C?

http://download.intel.com/support/motherboards/server/s5520ur/sb/e44031012_s5520ur_s5520urt_tps_r1_9.pdf

Выделение памяти потокам в GNU/Linux

- Страница памяти выделяется с NUMA-узла того потока, который первый к ней обратился (*first-touch policy*)
- Данные желательно инициализировать теми потоками, которые будут с ними работать

```
void run_parallel()
{
    double *a, *b, *c;

    // Allocate memory for 2-d array a[m, n]
    a = xmalloc(sizeof(*a) * m * n);
    b = xmalloc(sizeof(*b) * n);
    c = xmalloc(sizeof(*c) * m);

    for (int i = 0; i < m; i++) {
        for (int j = 0; j < n; j++)
            a[i * n + j] = i + j;
    }
    for (int j = 0; j < n; j++)
        b[j] = j;
```

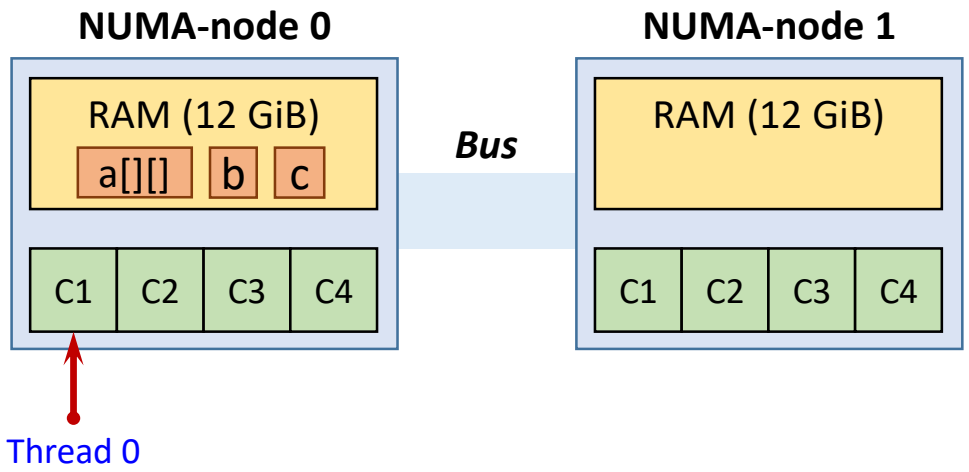

- Поток 0 запрашивает выделение памяти под массивы
- Пока хватает памяти, ядро выделяет страницы с NUMA-узла 0, затем с NUMA-узла 1

Выделение памяти потокам в GNU/Linux

- Страница памяти выделяется с NUMA-узла того потока, который первый к ней обратился (*first-touch policy*)
- Данные желательно инициализировать теми потоками, которые будут с ними работать

```
void run_parallel()
{
    double *a, *b, *c;

    // Allocate memory for 2-d array a[m, n]
    a = xmalloc(sizeof(*a) * m * n);
    b = xmalloc(sizeof(*b) * n);
    c = xmalloc(sizeof(*c) * m);

    for (int i = 0; i < m; i++) {
        for (int j = 0; j < n; j++)
            a[i * n + j] = i + j;
    }
    for (int j = 0; j < n; j++)
        b[j] = j;
```

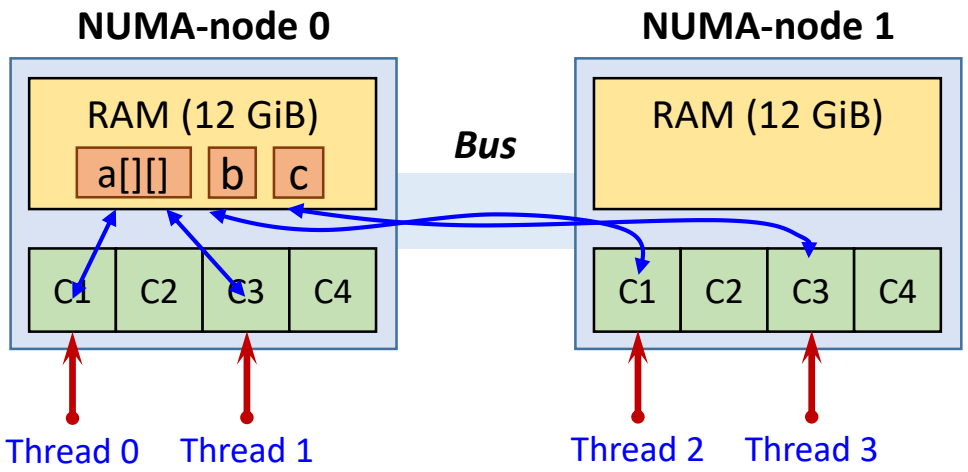

- Обращение к массивам из потоков NUMA-узла 1 будет идти через межпроцессорную шину в память узла 0

Параллельная инициализация массивов

```
void run_parallel()
{
    double *a, *b, *c;
    // Allocate memory for 2-d array a[m, n]
    a = xmalloc(sizeof(*a) * m * n);
    b = xmalloc(sizeof(*b) * n);
    c = xmalloc(sizeof(*c) * m);

    #pragma omp parallel
    {
        int nthreads = omp_get_num_threads();
        int threadid = omp_get_thread_num();
        int items_per_thread = m / nthreads;
        int lb = threadid * items_per_thread;
        int ub = (threadid == nthreads - 1) ? (m - 1) : (lb + items_per_thread - 1);

        for (int i = lb; i <= ub; i++) {
            for (int j = 0; j < n; j++)
                a[i * n + j] = i + j;
            c[i] = 0.0;
        }
    }
    for (int j = 0; j < n; j++)
        b[j] = j;

    /* ... */
}
```

Анализ эффективности OpenMP-версии (2)

M = N	Количество потоков								
	2			4		6		8	
	T_1	T_2	S_2	T_4	S_4	T_6	S_6	T_8	S_8
20 000 (~ 3 GiB)	0.73	0.34	**2.12**	0.24	**3.11**	0.23	**3.14**	0.25	**2.84**
40 000 (~ 12 GiB)	2.98	1.30	**2.29**	0.95	**3.11**	0.91	**3.21**	0.87	**3.38**
49 000 (~ 18 GiB)								1.23	3.69

Parallel initialization									
40 000 (~ 12 GiB)	2.98	1.22	**2.43**	0.67	**4.41**	0.65	**4.65**	0.54	**5.48**
49 000 (~ 18 GiB)								0.83	**5.41**

Суперлинейное ускорение (super-linear speedup): $S_p(n) > p$

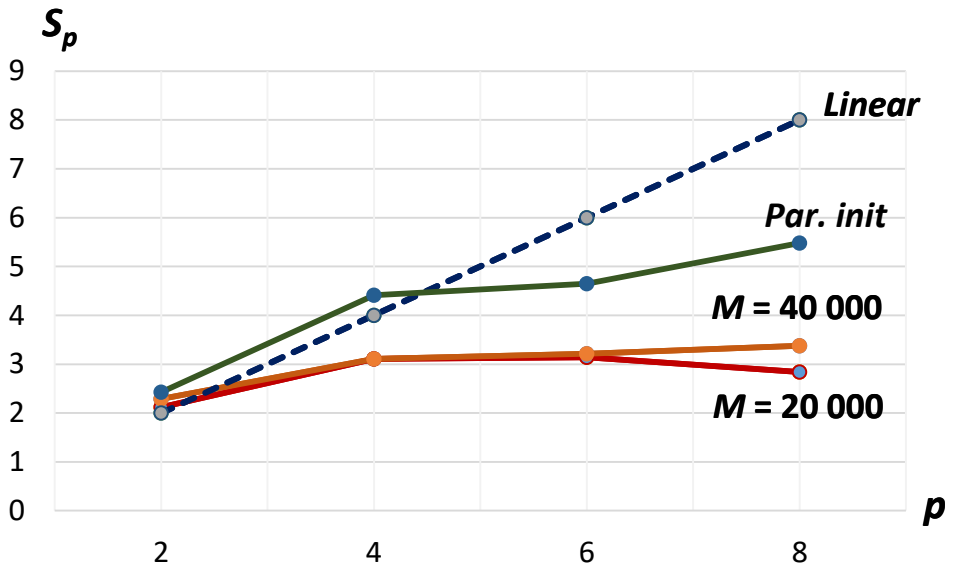

Улучшили масштабируемость

Дальнейшие оптимизации:

- Эффективный доступ к кеш-памяти
- Векторизация кода (SSE/AVX)
- …

Запуск OpenMP-программ на oak.cpct.sibsutis.ru

```
# Компилируем программу
$ make
gcc -std=c99 -g -Wall -O2 -fopenmp -c matvec.c -o matvec.o
gcc -o matvec matvec.o –fopenmp

# Ставим задание в очередь системы SLURM
$ sbatch ./task-slurm.job
Submitted batch job 3609

# Проверяем состояние очереди задач
$ squeue
             JOBID PARTITION     NAME     USER ST       TIME  NODES NODELIST(REASON)
              3609     debug task-slu   ivanov  R       0:01      1 cn2

# Открываем файл с результатом
$ cat ./slurm-3609.out
```

```
#!/bin/bash

#SBATCH --nodes=1 --ntasks-per-node=8

export OMP_NUM_THREADS=2
./matvec
```

Пользователь

Состояние

Узел кластера

Спасибо за внимание!

Время выполнения отдельных потоков

```
void matrix_vector_product_omp(double *a, double *b, double *c, int m, int n)
{
    #pragma omp parallel
    {
        double t = omp_get_wtime();
        int nthreads = omp_get_num_threads();
        int threadid = omp_get_thread_num();
        int items_per_thread = m / nthreads;
        int lb = threadid * items_per_thread;
        int ub = (threadid == nthreads - 1) ? (m - 1) : (lb + items_per_thread - 1);

        for (int i = lb; i <= ub; i++) {
            c[i] = 0.0;
            for (int j = 0; j < n; j++)
                c[i] += a[i * n + j] * b[j];
        }
        t = omp_get_wtime() - t;

        printf("Thread %d items %d [%d - %d], time: %.6f\n", threadid, ub - lb + 1, lb, ub, t);
    }
}
```

Мультиархитектура современных ВС

- Уровень одного узла (общая память)
  - ✓ Многопоточное программирование (intra-node): OpenMP, Intel TBB/Cilk Plus, C11/C++11 Threads
  - ✓ Программирование ускорителей (NVIDIA/AMD GPU, Intel Xeon Phi): NVIDA CUDA, OpenCL, OpenACC, OpenMP 4.0
- Множество вычислительных узлов (распределенная память):
  - ✓ MPI, Shmem, PGAS (Cray Chapel, IBM X10), Coarray Fortran, Global Arrays, …
- Уровень ядра процессора
  - ✓ Vectorization (SIMD: SSE/AVX, AltiVec), cache optimization, superscalar optimizations

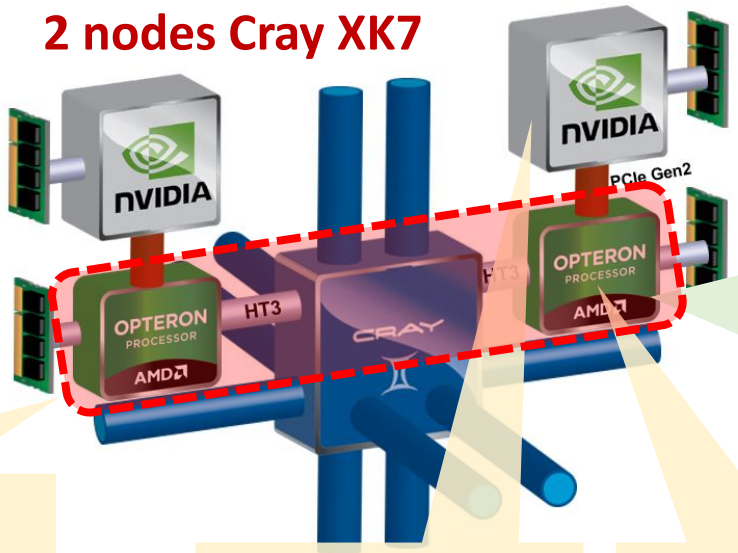

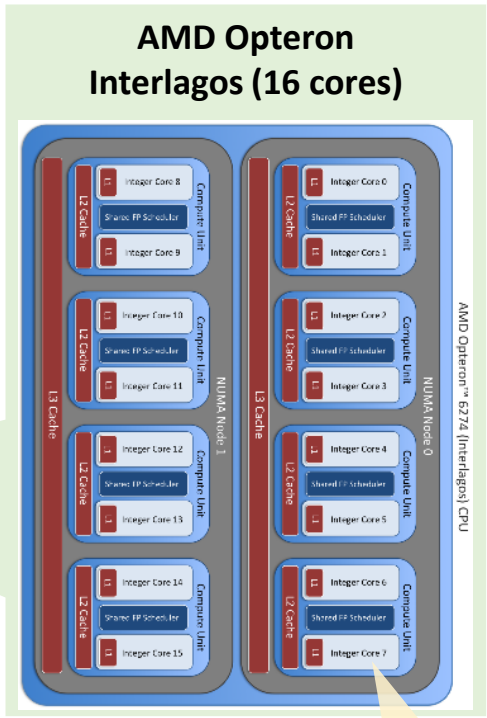

MPI, Cray Chapel, Shmem, Coarray Fortran, Unified Parallel C

NVIDIA CUDA, OpenCL, OpenACC

OpenMP, Intel TBB, Cilk, POSIX Threads

SSE/AVX