Курс «Архитектурно-ориентированная оптимизация кода»

# Управление памятью в NUMA-системах

Михаил Курносов

# NUMA (Non-Uniform Memory Access)

- **NUMA-система — многопроцессорная система с общей памятью:**
  - каждый процессор (группа процессоров, ядер) имеют доступ к своей физической памяти через выделенный контроллер
  - доступ к физической памяти других процессоров осуществляется через межпроцессорное соединение

- **NUMA node** — совокупность процессорных ядер и их локальной памяти
  (NUMA-узел может не иметь процессора)

- **Local node** — локальный для ядра NUMA-узел (доступ к памяти через локальный контроллер памяти)

- **Remote node** — удаленный NUMA-узел (доступ к памяти через межпроцессорное соединение + контроллер памяти)

# NUMA (Non-Uniform Memory Access)

- **Разбиение на NUMA-узлы программно-настраиваемое (BIOS/UEFI):**
  - один контроллер памяти — один NUMA-узел
  - один контроллер памяти — два NUMA-узла
  - все контроллеры памяти — один NUMA-узел (NUMA-режим отключен, прозрачное чередование доступа к памяти NUMA-узлов)
  - Intel Sub-NUMA Clustering, AMD EPYC Channel-Interleaving, Huawei Channel Interleaving/One Numa Per Socket

- **Межпроцессорное соединение** (Intel UPI, AMD Infinity Fabric, Huawei Hydra) обеспечивает когерентность кеш-памяти процессоров

- Ядро получает информацию о NUMA-топологии из таблицы SRAT (System/Static Resource Affinity Table, ACPI Specification) https://uefi.org/specs/ACPI/6.5/17_NUMA_Architecture_Platforms.html

2 x Intel Cascade Lake (20 cores, 2 Sub-NUMA Clusters)

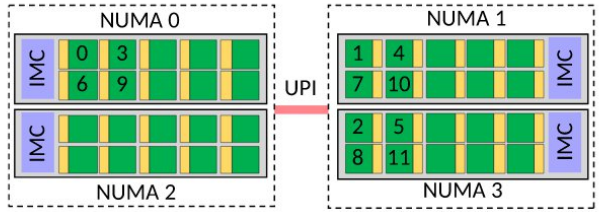


*Distance[i][j]*

| i/j | 0 | 1 | 2 | 3 |
|---|---|---|---|---|
| 0 | 10 | 21 | 11 | 21 |
| 1 | 21 | 10 | 21 | 11 |
| 2 | 11 | 21 | 10 | 21 |
| 3 | 21 | 11 | 21 | 10 |

2 x HiSilicon TaiShan v110 (64 cores, 2 NUMA, ARMv8)

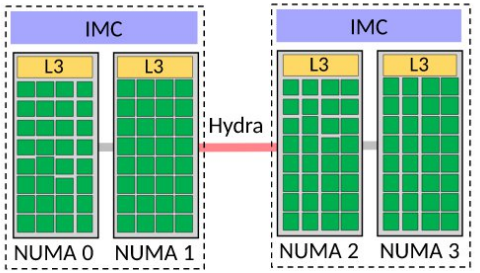


*Distance[i][j]*

| i/j | 0 | 1 | 2 | 3 |
|---|---|---|---|---|
| 0 | 10 | 16 | 32 | 33 |
| 1 | 16 | 10 | 25 | 32 |
| 2 | 32 | 25 | 10 | 16 |
| 3 | 33 | 32 | 16 | 10 |

2 x AMD EPYC (32 cores, 4 NUMA)

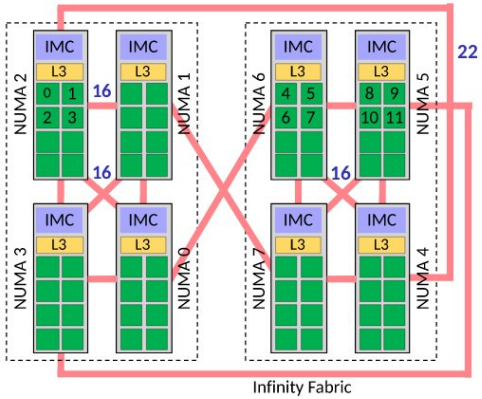


*Distance[i][j]*

| i/j | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
|---|---|---|---|---|---|---|---|---|
| 0 | 10 | 16 | 16 | 16 | 28 | 28 | 22 | 28 |
| 1 | 16 | 10 | 16 | 16 | 28 | 28 | 28 | 22 |
| 2 | 16 | 16 | 10 | 16 | 22 | 28 | 28 | 28 |
| 3 | 16 | 16 | 16 | 10 | 28 | 22 | 28 | 28 |
| 4 | 28 | 28 | 22 | 28 | 10 | 16 | 16 | 16 |
| 5 | 28 | 28 | 28 | 22 | 16 | 10 | 16 | 16 |
| 6 | 22 | 28 | 28 | 28 | 16 | 16 | 10 | 16 |
| 7 | 28 | 22 | 28 | 28 | 16 | 16 | 16 | 10 |

# GNU/Linux NUMA

## двухпроцессорных сервер, 2 NUMA-узла

```
$ grep NUMA=y /boot/config-`uname -r`
CONFIG_NUMA=y
CONFIG_AMD_NUMA=y
CONFIG_X86_64_ACPI_NUMA=y
CONFIG_ACPI_NUMA=y

$ dmesg | grep -i numa
[    0.000000] NUMA: Initialized distance table, cnt=2
[    0.000000] NUMA: Node 0 [mem 0x00000000-0x7fffffff] + [mem 0x100000000-0x87fffffff] -> [mem 0x00000000-0x87fffffff]
[    0.000000] mempolicy: Enabling automatic NUMA balancing. Configure with numa_balancing= or the kernel.numa_balancing
sysctl
[    0.352790] pci_bus 0000:ff: Unknown NUMA node; performance will be reduced
[    0.361236] pci_bus 0000:7f: Unknown NUMA node; performance will be reduced
[    0.390115] pci_bus 0000:00: on NUMA node 0
[    0.397086] pci_bus 0000:80: on NUMA node 1


$ cat /sys/devices/system/node/possible
0-1

$ cat /sys/devices/system/node/online
0-1

$ lscpu | grep -i numa
  NUMA node(s):          2
  NUMA node0 CPU(s):     0-7,16-23
  NUMA node1 CPU(s):     8-15,24-31
```

# GNU/Linux NUMA

## Система с одним многоядерным процессором

```
$ grep NUMA=y /boot/config-`uname -r`
CONFIG_NUMA=y
CONFIG_AMD_NUMA=y
CONFIG_X86_64_ACPI_NUMA=y
CONFIG_ACPI_NUMA=y

$ cat /sys/devices/system/node/online
0

$ lscpu | grep -i numa
NUMA node(s):                    1
NUMA node0 CPU(s):               0-7
```

- https://www.kernel.org/doc/html/latest/admin-guide/mm/numa_memory_policy.html
- https://www.kernel.org/doc/Documentation/ABI/stable/sysfs-devices-node
- https://www.kernel.org/doc/html/latest/admin-guide/numastat.html

# GNU/Linux NUMA

двухпроцессорных сервер, 2 NUMA-узла

```
$ numactl --hardware
available: 2 nodes (0-1)
node 0 cpus: 0 1 2 3 4 5 6 7 16 17 18 19 20 21 22 23
node 0 size: 32072 MB
node 0 free: 31609 MB
node 1 cpus: 8 9 10 11 12 13 14 15 24 25 26 27 28 29 30 31
node 1 size: 32209 MB
node 1 free: 31243 MB
node distances:
node   0   1
  0:  10  21
  1:  21  10

$ numactl --show
policy: default
preferred node: current
physcpubind: 0 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31
cpubind: 0 1
nodebind: 0 1
membind: 0 1
```

# GNU/Linux NUMA

- Для каждого NUMA-узла ядро поддерживает список физический страниц памяти, зон памяти (memory zone), а также текущую статистику использования ресурсов

```
$ cat /proc/zoneinfo
Node 0, zone      DMA
...
Node 0, zone    DMA32
  pages free     473189
...
Node 0, zone   Normal
  pages free     7615936
...
Node 1, zone      DMA
...
Node 1, zone    DMA32
...
Node 1, zone   Normal
  pages free     7999278
...
```

```
$ cat /sys/devices/system/node/node0/meminfo
Node 0 MemTotal:       32842028 kB
Node 0 MemFree:        32369688 kB
Node 0 MemUsed:          472340 kB
Node 0 SwapCached:            0 kB
...
Node 0 HugePages_Total:     0
Node 0 HugePages_Free:      0
Node 0 HugePages_Surp:      0

$ cat /sys/devices/system/node/node0/vmstat
nr_free_pages 8092422
...
numa_hit 2216296
numa_miss 0
numa_foreign 0
numa_interleave 2021
numa_local 2213164
numa_other 3118
...
```

# Политики управления памятью (Linux Memory Policy)

- **Политика памяти (memory policy)** определяет с какого NUMA-узла ядро будет выделять физические страницы память
- **Области действия политики (scope)**
  - System Default Policy — выделение страниц памяти с NUMA-узла локального для ядра, на котором выполняется процесс (local allocation)
  - Task/Process Policy — политика выделения страниц памяти для всего адресного пространства заданного процесса/потока (по умолчанию — System Default Policy)
  - VMA Policy — политика выделения страниц памяти для заданного диапазона адресов адресного пространства процесса
  - Shared Policy — политика выделения страниц памяти для заданной области, которая совместно используется несколькими процессами
- **Режим действия политики (mode)** определяет NUMA-узлы, с которых выделяются страницы памяти
  - Bind — страница памяти выделяется с ближайшего NUMA-узла из заданного множества
  - Preferred — страница памяти выделяется с заданного NUMA-узла, в случае ошибки память выделяется с ближайшего узла с достаточным объемом свободной памяти
  - Interleaved — страницы памяти циклически выделяются с разных NUMA-узлов (чередуются)
  - Preferred Many — страница памяти выделяется NUMA-узла из заданного множества, в случае ошибки память выделяется с ближайшего узла с достаточным объемом свободной памяти

# Linux Memory Policy API & CLI

- **Task Memory Policy**
  - `long set_mempolicy(int mode, const unsigned long *nmask, unsigned long maxnode)`
  - `long get_mempolicy(int *mode, const unsigned long *nmask, unsigned long maxnode, void *addr, int flags)`
- **VMA Memory Policy**
  - `long mbind(void *start, unsigned long len, int mode, const unsigned long *nmask, unsigned long maxnode, unsigned flags)`

```
# Выделение страниц памяти с NUMA-узлов 0, 1, привязка процесса к процессорам NUMA-узла 0
$ numactl --membind=0,1 --cpubind=0 ./app

# Чередование выделения страниц памяти с NUMA-узлов 0, 1
$ numactl --interleave=0,1 ./app

# Выделение страниц памяти с локального NUMA-узла
$ numactl --localalloc ./app
```

# Linux NUMA-aware Scheduler

- **Планировщик процессов Linux формирует иерархические домены (scheduling domain), соответствующие NUMA-топологии системы**
- Уровни формирования доменов:
  - Уровень аппаратных потоков одного ядра (L1): балансирование загрузки относительно частое, небольшие издержки из-за переноса процесса в пределах группы (имеют общую кеш-память)
  - Уровень ядер одного процессора (L2)**:** балансирование загрузки относительно редко, издержки из-за переноса процесса в пределах домена (на новом ядре нет данных в кеш-памяти)
  - Уровень процессоров NUMA-узла (L3): балансирование загрузки осуществляется редкое, высокие издержки из-за переноса процесса в пределах домена

- Планирование:
  - Процесс запланирован на выполнение: остается на том же процессоре или перемещается на менее загруженный в пределах домена L1
  - Запускается новый процесс (exec()): данных в кеш-памяти нет, планировщик поднимается по иерархии доменов и выбирает наименее загруженный процессор

- Scheduling domains // https://lwn.net/Articles/80911/
- Scheduler domains // https://docs.kernel.org/scheduler/sched-domains.html

# Automatic NUMA Balancing

# Automatic NUMA Balancing

- Ядро Linux отслеживает и периодически перемещает страницы виртуальной памяти на NUMA-узел, с которого к ним часто обращаются процессы

```
$ cat /proc/sys/kernel/numa_balancing
1

# Disable Automatic NUMA Balancing (current session)
echo 0 > /proc/sys/kernel/numa_balancing

# Disable Automatic NUMA Balancing
$ sysctl -w kernel.numa_balancing=0
```

# Automatic NUMA Balancing

- Ядро периодически сканирует адресное пространство процесса и помечает часть страниц памяти для срабатывания обработчика при следующем обращении к ним (NUMA hinting fault — NHF)
- При срабатывании обработчика NHF ядру становится известен источник запроса — процесс и его NUMA-узел
- Страница переносится на другой NUMA-узел если к ней обращаются дважды с одного и того же NUMA-узла (shared fault) или дважды обращается один и тот же процесс (private fault)

- Многопоточные приложения:
  - Псевдослучайное многократное обращение к произвольным страницам из всех потоков: страницы мигрируют между NUMA-узлами
  - Каждый поток обращается к своей области памяти (группе страниц): минимум переносов страниц

```
$ sysctl -a | grep numa_balancing
kernel.numa_balancing_scan_delay_ms = 1000        # Задержка перед первым сканирование памяти процесса
kernel.numa_balancing_scan_period_max_ms = 60000  # Макс. время сканирования памяти процесса
kernel.numa_balancing_scan_period_min_ms = 1000   # Мин. время сканирования памяти процесса
kernel.numa_balancing_scan_size_mb = 256          # Размер окна сканирования для одного прохода
```

- Rik van Riel. **Automatic NUMA Balancing** // https://events.static.linuxfound.org/sites/events/files/slides/summit2014_riel_chegu_w_0340_automatic_numa_balancing_0.pdf

# Статистика выделения страниц памяти с NUMA-узла

```
$ cat /sys/devices/system/node/node0/numastat
numa_hit 3425512
numa_miss 0
numa_foreign 0
interleave_hit 2021
local_node 3421949
other_node 3505
```

```
$ cat /sys/devices/system/node/node1/numastat
numa_hit 6822476
numa_miss 0
numa_foreign 0
interleave_hit 1000
local_node 6814006
other_node 8434
```

| | |
|---|---|
| numa_hit | Процесс запрашивает выделение страницы памяти с этого узла, запрос успешно удовлетворяется |
| numa_miss | Процесс запрашивает выделение памяти с другого узла, но память выделятся с текущего узла |
| numa_foreign | Процесс запрашивает выделение памяти с этого узла, но память выделяется с другого узла |
| local_node | Процесс запущен процессоре этого узла и память выделена с этого узла |
| other_node | Процесс запущен процессоре другого узла, но память выделена с этого узла |
| interleave_hit | При чередовании запрашивается выделение памяти с текущего узла, запрос успешно удовлетворяется |

- Если запрос процесса на выделение памяти с предпочитаемого узла удовлетворен, то numa_hit увеличивается на предпочитаемом узле
- В противном случае, на предпочитаемом узле увеличивается numa_foreign, а на узле с которого выделили память увеличивается numa_miss

https://docs.kernel.org/admin-guide/numastat.html

# Сводная статистика выделения страниц памяти с NUMA-узлов

```
$ grep -i numa /proc/vmstat
numa_hit 10206402
numa_miss 0
numa_foreign 0
numa_interleave 3021
numa_local 10194405
numa_other 11903

numa_pte_updates 350494             # Количество страниц отмеченных для проверки доступа (NHF)
numa_huge_pte_updates 0             # Количество больших страниц отмеченных для проверки доступа (NHF)
numa_hint_faults 314809             # Количество NHF
numa_hint_faults_local 151721       # Количество NHF с локальных узлов
numa_pages_migrated 62982           # Количество перемещенных страниц (все узлы, все приложения)
```

# DGMEV: Matrix-Vector Multiplication

## последовательная версия

```
enum { M = 10000, N = 10000 };

// dgemv: c[m] = a[m][n] * b[n]
void dgemv(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];
    }
}

int main()
{
    printf(«DGEMV (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();
    return 0;
}
```

```
void run_serial()
{
    double *a, *b, *c;
    a = malloc(sizeof(*a) * M * N);
    b = malloc(sizeof(*b) * N);
    c = malloc(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();
    dgemv(a, b, c, M, N);
    t = wtime() - t;

    double gflops = M * N * 2 * 1E-6 / t;
    printf(«Elapsed time (sec): %.6f;  %.2f GFLOPS\n»,
           t, gflops);

    free(a);
    free(b);
    free(c);
}
```

# DGMEV: Matrix-Vector Multiplication

## многопоточная версия

```
// dgemv: c[m] = a[m][n] * b[n]
void dgemv_omp(double *a, double *b, double *c, int m, int n)
{
    #pragma omp parallel for
    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];
    }
}
```

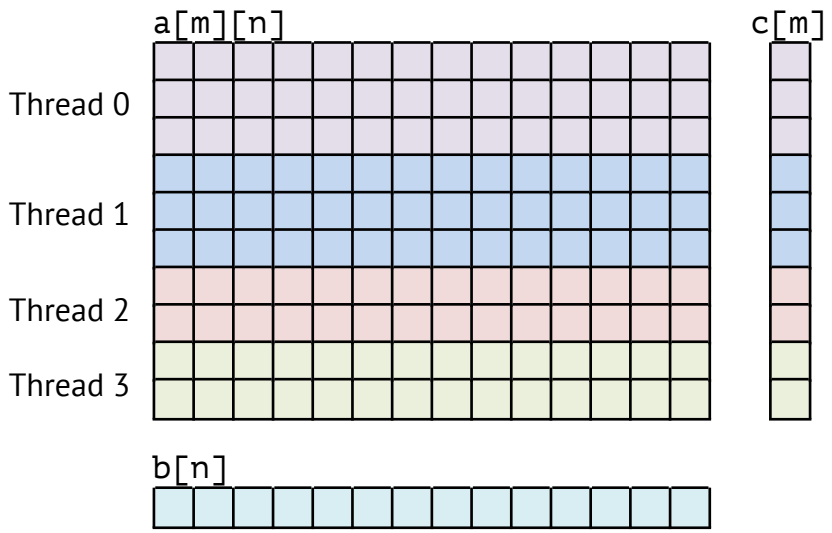


```
void run_parallel()
{
    double *a, *b, *c;
    a = malloc(sizeof(*a) * M * N);
    b = malloc(sizeof(*b) * N);
    c = malloc(sizeof(*c) * M);
    for (int i = 0; i < M; i++) {
        for (int j = 0; j < N; j++)
            a[i * N + j] = i + j;
    }
    for (int j = 0; j < N; j++)
        b[j] = j;

    double t = wtime();
    dgemv_omp(a, b, c, M, N);
    t = wtime() - t;

    double gflops = M * N * 2 * 1E-6 / t;
    printf(«Elapsed time (sec): %.6f;  %.2f GFLOPS\n»,
           t, gflops);

    free(a);
    free(b);
    free(c);
}
```

- M=N=20000, 16 threads, 2 x CPU (Intel Xeon E5-2620 v4, 8 cores)
- Speedup 4.6

# DGMEV: Matrix-Vector Multiplication

## многопоточная версия

```
// dgemv: c[m] = a[m][n] * b[n]
void dgemv_omp(double *a, double *b, double *c, int m, int n)
{
    #pragma omp parallel for
    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];
    }
}
```

- Главный поток выделяет страницы памяти под массивы a, b, c со своего локального NUMA-узла (default policy, local alloc)
- Страница памяти выделяются с NUMA-узла процесса, который первый к ней обратился (Linux first-touch policy)
- Потоки на ядрах удаленного NUMA-узла обращаются за своими элементами a[][] через межпроцессорное соединение
- **Рекомендация**: каждый поток, при возможности, выделяет страницы памяти для своих данных с локального NUMA-узла

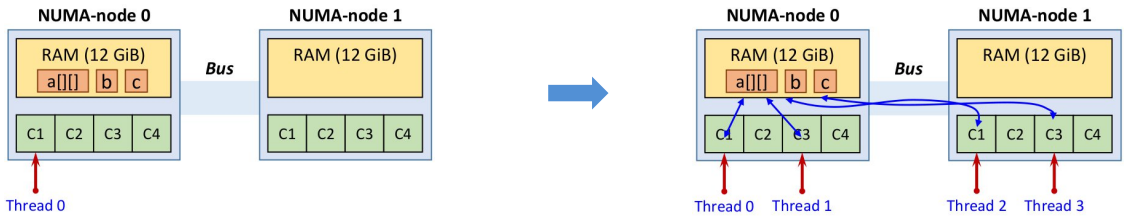


```
void run_parallel()
{
    double *a, *b, *c;
    a = malloc(sizeof(*a) * M * N);
    b = malloc(sizeof(*b) * N);
    c = malloc(sizeof(*c) * M);
    for (int i = 0; i < M; i++) {
        for (int j = 0; j < N; j++)
            a[i * N + j] = i + j;
    }
    for (int j = 0; j < N; j++)
        b[j] = j;

    double t = wtime();
    dgemv_omp(a, b, c, M, N);
    t = wtime() - t;

    double gflops = M * N * 2 * 1E-6 / t;
    printf(«Elapsed time (sec): %.6f;  %.2f GFLOPS\n»,
           t, gflops);

    free(a);
    free(b);
    free(c);
}
```

# DGMEV: Matrix-Vector Multiplication

## инициализация с выделением страниц памяти с локальных NUMA-узлов

```
// dgemv: c[m] = a[m][n] * b[n]
void dgemv_omp(double *a, double *b, double *c, int m, int n)
{
    #pragma omp parallel for
    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];
    }
}
```

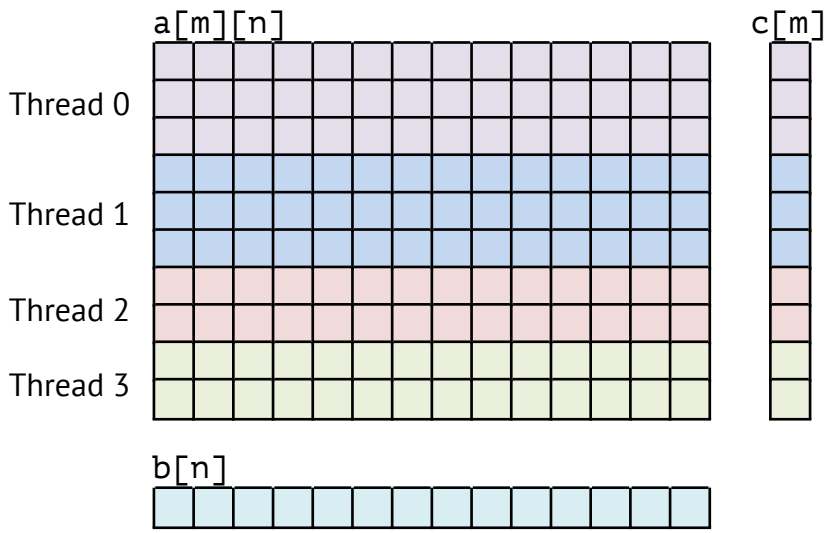


```
void run_parallel()
{
    double *a, *b, *c;
    a = malloc(sizeof(*a) * M * N);
    b = malloc(sizeof(*b) * N);
    c = malloc(sizeof(*c) * M);
    #pragma omp parallel for
    for (int i = 0; i < M; i++) {
        for (int j = 0; j < N; j++)
            a[i * N + j] = i + j;
    }
    for (int j = 0; j < N; j++)
        b[j] = j;

    double t = wtime();
    dgemv_omp(a, b, c, M, N);
    t = wtime() - t;

    double gflops = M * N * 2 * 1E-6 / t;
    printf(«Elapsed time (sec): %.6f;  %.2f GFLOPS\n»,
           t, gflops);

    free(a);
    free(b);
    free(c);
}
```

- M=N=20000, 16 threads, 2 x CPU (Intel Xeon E5-2620 v4, 8 cores)
- **Speedup 11.2**

# Автоматический перенос страниц памяти (Automatic NUMA Balancing)

`kernel.numa_balancing=1`

```
$ ./dgemv_omp
# NREPS = 1
/proc/vmstat: numa_pages_migrated 924689
DGEMV C=A*B (c[m] = a[m, n] * b[n]; m = 10000, n = 10000)
Memory used: 763 MiB
Master thread NUMA node: 1 (cpu 24)
Elapsed time (sec): 0.064324;  3109.27 GFLOPS

 Performance counter stats for './dgemv_omp':
                 0      cpu-migrations:u

/proc/vmstat: numa_pages_migrated 924689
```

0
4K pages migrated
(16 threads, 2 NUMA nodes)

```
$ ./dgemv_omp
# NREPS = 100
/proc/vmstat: numa_pages_migrated 924689
DGEMV C=A*B (c[m] = a[m, n] * b[n]; m = 10000, n = 10000)
Memory used: 763 MiB
Master thread NUMA node: 1 (cpu 24)
Elapsed time (sec): 0.053285;  3753.42 GFLOPS

 Performance counter stats for './dgemv_omp'
                 0      cpu-migrations:u

/proc/vmstat: numa_pages_migrated 1022354
```

**97 665**
4K pages migrated
(16 threads, 2 NUMA nodes)

```c
void run_parallel()
{
    double *a, *b, *c;
    a = malloc(sizeof(*a) * M * N);
    b = malloc(sizeof(*b) * N);
    c = malloc(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;

    int NREPS = 100;  // Многократный проход по массиву
    double t = wtime();
    for (int i = 0; i < NREPS; i++)
      dgemv_omp(a, b, c, M, N);
    t = wtime() - t;
    t /= NREPS;

    double gflops = M * N * 2 * 1E-6 / t;
    printf(«Elapsed time (sec): %.6f;  %.2f GFLOPS\n»,
           t, gflops);

    free(a); free(b); free(c);
}
```

- За несколько проходов по массивам a, b, c включается балансировщик и страницы переносятся на другой NUMA-узел

# Автоматический перенос страниц памяти (Automatic NUMA Balancing)

`kernel.numa_balancing=1`

```
OMP_NUM_THREADS=16 ./dgemv_omp    # NREPS=1000
```

```
$ sudo numatop
*** Monitoring 394 processes and 480 threads (interval: 5.0s)
   PID            PROC     RMA(K)     LMA(K)    RMA/LMA         CPI     *CPU%%
 75634       dgemv_omp     5509.5     3474.8        1.6        0.58        6.9
 75621         numatop       10.7       74.0        0.1        1.07        0.0
  1341        telegraf      107.0       52.7        2.0        1.59        0.0
  1110     systemd-oom       13.0       11.6        1.1        3.78        0.0
...

*** Monitoring 390 processes and 476 threads (interval: 5.0s)
   PID            PROC     RMA(K)     LMA(K)    RMA/LMA         CPI     *CPU%%
 75634       dgemv_omp    16415.3    43396.5        0.4        0.49       41.6
 79577         numatop       10.7       60.8        0.2        1.12        0.1
  1341        telegraf      141.4      121.3        1.2        1.66        0.1
 79462     kworker/0:2       27.8       26.7        1.0        2.90        0.0
  1110     systemd-oom       17.4       12.5        1.4        3.66        0.0
```

- Часть потоков обращаются к памяти удаленного NUMA-узла
- Обращений к памяти удаленного узла больше на 60% (RMA/LMA=1.6)

- Страницы памяти перенесены
- Доминируют обращения к памяти локальных узлов

- RMA — Remote Memory Access
- LMA — Local Memory Access

`https://github.com/intel/numatop`
`http://01.org/numatop`

- Автоматическая миграция страниц положительно влияет на производительность приложений, многократно обращающихся к одним и тем же страницам памяти
- Если dgemv_omp() вызывается один раз, балансировщик не включается
- Если dgemv_omp() вызывается многократно, то страницы с данными массива a[][] перемещаются на другие NUMA-узлы, повышается коэффициент локальных обращений

# Автоматический перенос страниц памяти (Automatic NUMA Balancing)

`kernel.numa_balancing=1`

```
OMP_NUM_THREADS=16 ./dgemv_omp_init
```

```
$ sudo numatop
*** Monitoring 393 processes and 479 threads (interval: 5.0s)
   PID            PROC     RMA(K)     LMA(K)    RMA/LMA         CPI     *CPU%%
 79877    dgemv_omp_i      627.7     5576.8        0.1        0.68        8.7
  1341       telegraf       70.0      117.8        0.6        2.77        0.1
 79864        numatop       10.3       18.7        0.6        1.42        0.0
  1110    systemd-oom        7.1        5.6        1.3        4.16        0.0
...

*** Monitoring 393 processes and 479 threads (interval: 5.0s)
   PID            PROC     RMA(K)     LMA(K)    RMA/LMA         CPI     *CPU%%
 79877    dgemv_omp_i     2420.6    19563.9        0.1        0.66       32.2
 79864        numatop       15.8       70.4        0.2        1.06        0.1
 79858    kworker/0:0       56.4       57.6        1.0        3.57        0.0
 79666    kworker/u65       47.5       49.0        1.0        3.09        0.0
  1110    systemd-oom       18.7       15.6        1.2        3.14        0.0
```

- Инициализация потоками своих областей матрицы a[][] обеспечивает выделение страниц памяти с локальных NUMA-узлов
- В версии dgemv_omp_init доминируют обращения к памяти локальных NUMA-узлов (RMA/LMA=0.1)

# Отключение автоматического переноса страниц памяти

`kernel.numa_balancing=0`

`OMP_NUM_THREADS=16 ./dgemv_omp`

```
$ sudo numatop
*** Monitoring 387 processes and 473 threads (interval: 5.0s)
   PID            PROC     RMA(K)     LMA(K)    RMA/LMA         CPI     *CPU%%
 76078       dgemv_omp    11784.2     5720.1        2.1        0.55        9.9
  1341        telegraf       95.0       51.4        1.9        1.47        0.0
 76065         numatop        8.3       22.8        0.4        1.18        0.0
 76077            perf        2.0       62.6        0.0        0.80        0.0
...

*** Monitoring 387 processes and 473 threads (interval: 5.0s)
   PID            PROC     RMA(K)     LMA(K)    RMA/LMA         CPI     *CPU%%
 76078       dgemv_omp    31918.4    34492.6        0.9        0.53       42.1
 76065         numatop       13.7      115.8        0.1        1.16        0.2
 75519     kworker/u65       43.9       46.4        0.9        3.29        0.0
 76018     kworker/0:1       23.0       20.1        1.1        2.93        0.0
  1110     systemd-oom       17.5       13.3        1.3        4.54        0.0
```

# Отключение автоматического переноса страниц памяти

`kernel.numa_balancing=0`

```
OMP_NUM_THREADS=16 ./dgemv_omp_init
```

```
$ sudo numatop
*** Monitoring 389 processes and 475 threads (interval: 5.0s)
   PID            PROC      RMA(K)      LMA(K)    RMA/LMA         CPI      *CPU%%
 76208     dgemv_omp_i       264.3     35127.9         0.0        0.49        25.7
 76195         numatop         8.5        33.2         0.3        1.18         0.0
  1183       sssd_sudo        69.7        68.8         1.0        2.68         0.0
  1110     systemd-oom        11.1         9.2         1.2        4.02         0.0
    16     ksoftirqd/0        19.6        20.0         1.0        2.85         0.0
 76156     kworker/0:0        16.7        16.8         1.0        2.77         0.0
 75981     kworker/u65         4.4         8.2         0.5        3.79         0.0
```

M=N=20000, 16 threads, 2 x Intel Xeon E5-2620 v4 (8 cores), linux 5.18.11

| NUMA Balancing | dgemv_omp | | dgemv_omp_init | |
|---|---|---|---|---|
| | Time (sec) | GFLOPS | Time (sec) | GFLOPS |
| NUMA Balancing off | 0.248783 | 3215.65 | 0.183197 | 4366.88 |
| NUMA Balancing on | 0.248147 | 3223.89 | 0.183158 | **4367.82** |

# Сегмент разделяемой памяти с физическими страницами с разных NUMA-узлов

**Shared memory segment:**

```
addr = mmap(NULL, size, PROT_READ | PROT_WRITE, MAP_SHARED, fd, 0)
```

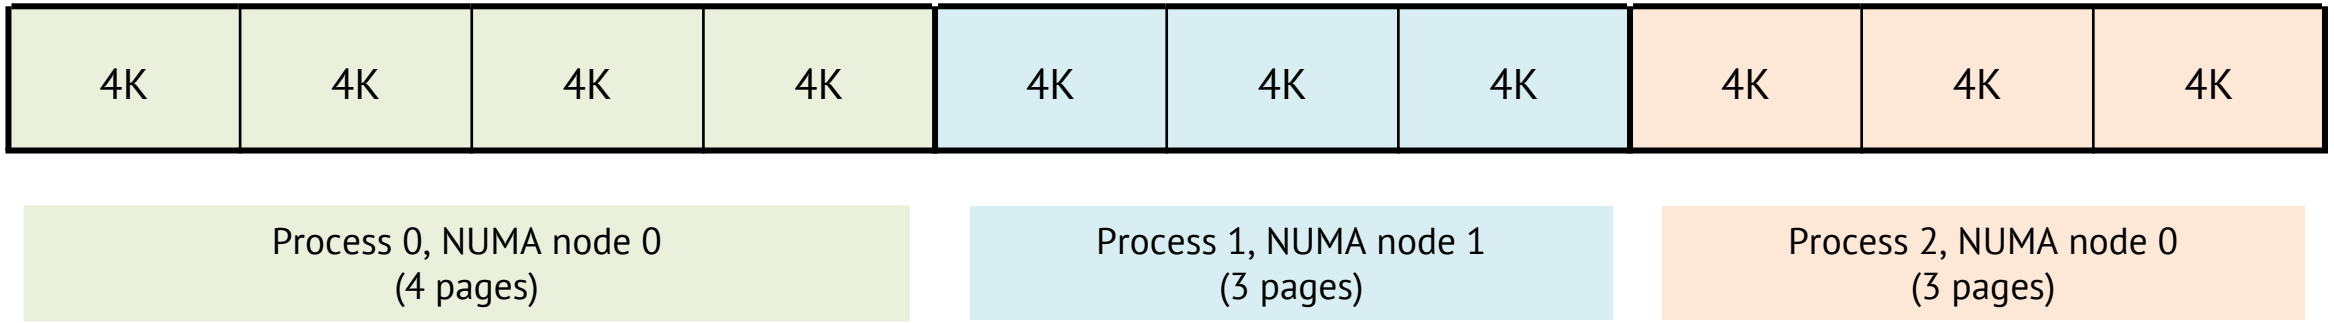


- **Три процесса совместно используют область памяти для передачи информации друг-другу**
- Процессу 0 требуется 4 страницы памяти (32KB)
- Процессу 1 требуется 3 страницы памяти (12KB)
- Процессу 2 требуется 3 страницы памяти (12KB)
- **Задача**: для минимизации времени доступа к своим блокам каждому процессу необходимо выделить физические страницы памяти со своих NUMA-узлов

# Сегмент разделяемой памяти с физическими страницами с разных NUMA-узлов

**Shared memory segment:**

```
addr = mmap(NULL, size, PROT_READ | PROT_WRITE, MAP_SHARED, fd, 0)
```

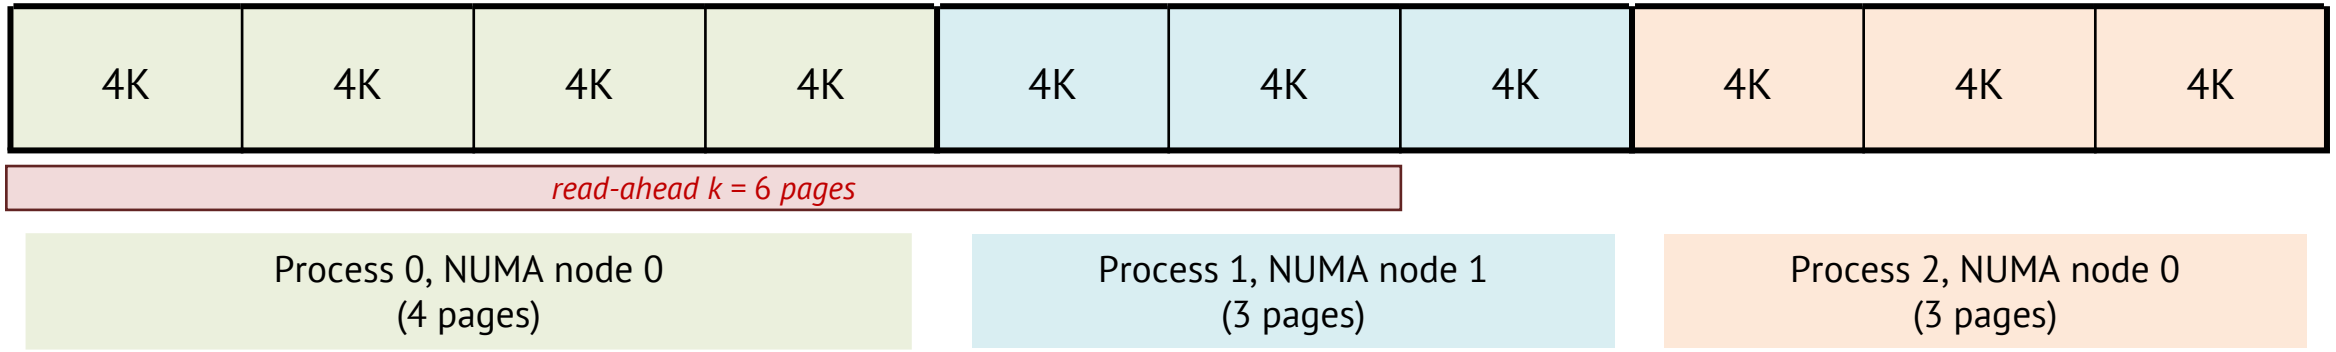


- **Использование политики ядра first-touch policy (local alloc) + madvise(addr, size, MADV_RANDOM)**
- Каждый процесс инициализирует первый байт памяти своих страницы, что приведет к их выделению с локальных NUMA-узлов
- **Проблема**:
  - если процесс 0 первым инициализирует страницу памяти ядро может активировать механизм спекулятивного выделения *k* последовательных страниц памяти с NUMA-узла 0 (read-ahead)
  - при $k > 4$ некоторые страницы блока процесса 1 будут выделены с узла 0
- **Решение**: madvise(addr, size, MADV_RANDOM) — уведомляем ядро о псевдослучайном обращении к страницам (рекомендация ядру отключить read-ahead)