

Векторизация кода для Intel® Xeon Phi™ с помощью функций-интринсиков



Виктор Гетманский

Ефим Сергеев

Олег Шаповалов

Дмитрий Крыжановский

Singulairis Lab, Ltd.

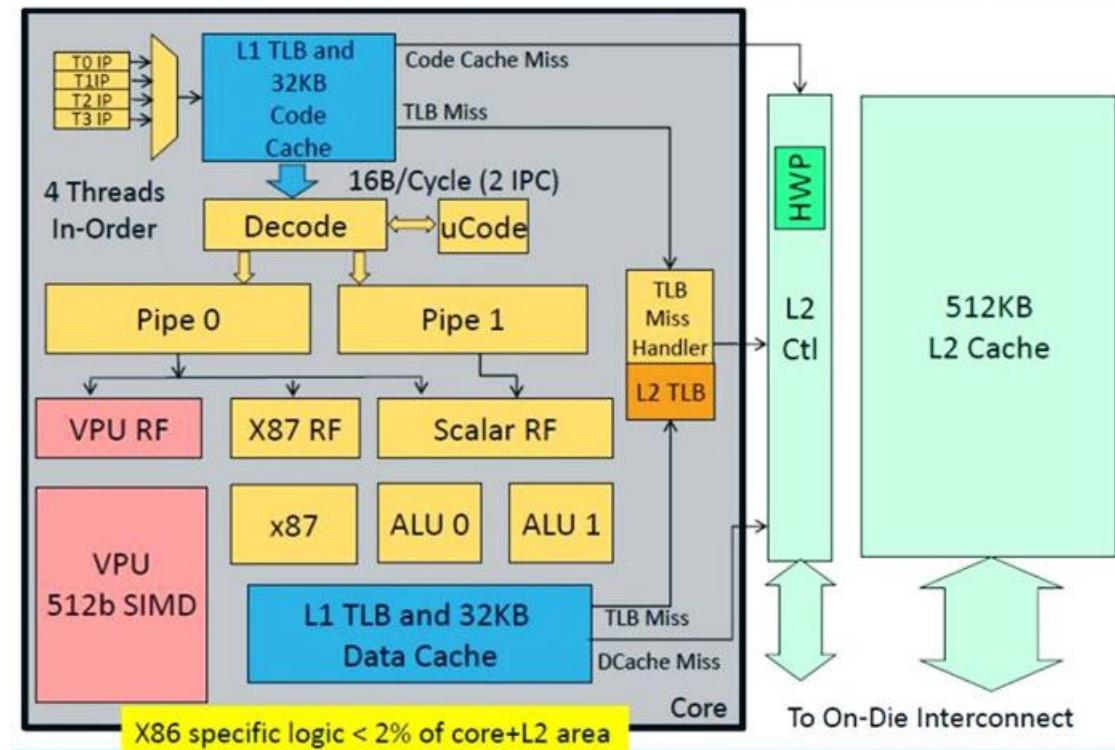
Volgograd State Technical University

2015

- Архитектура и возможности векторизации
Intel® Xeon Phi™

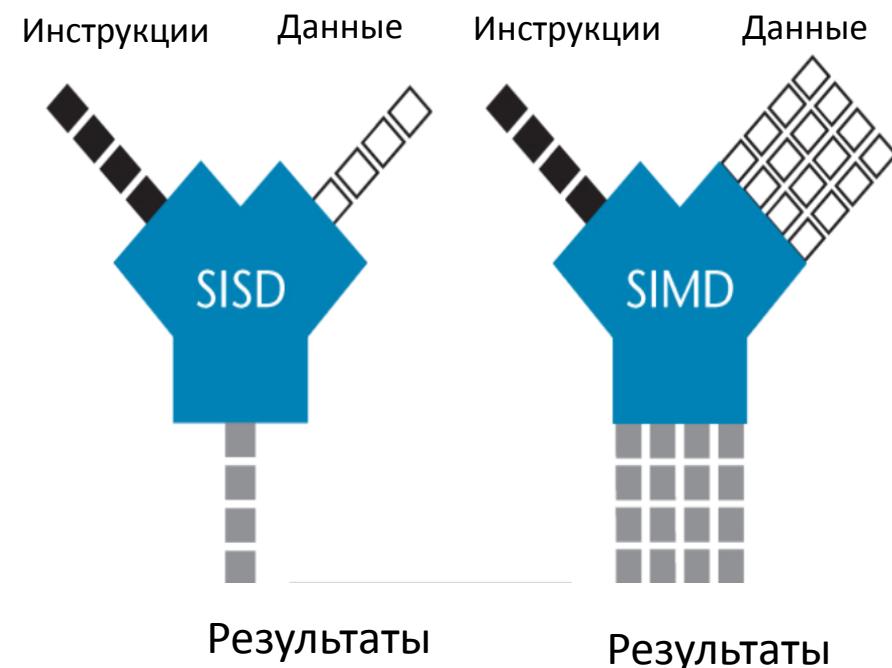
- Выравнивание памяти
- Программные способы векторизации
- Интринсики. Типы операций
- Пример умножения матрицы на вектор
- Пример умножения «упакованных» матриц
- Сравнение производительности

Микроархитектура ядра Intel® Xeon Phi™



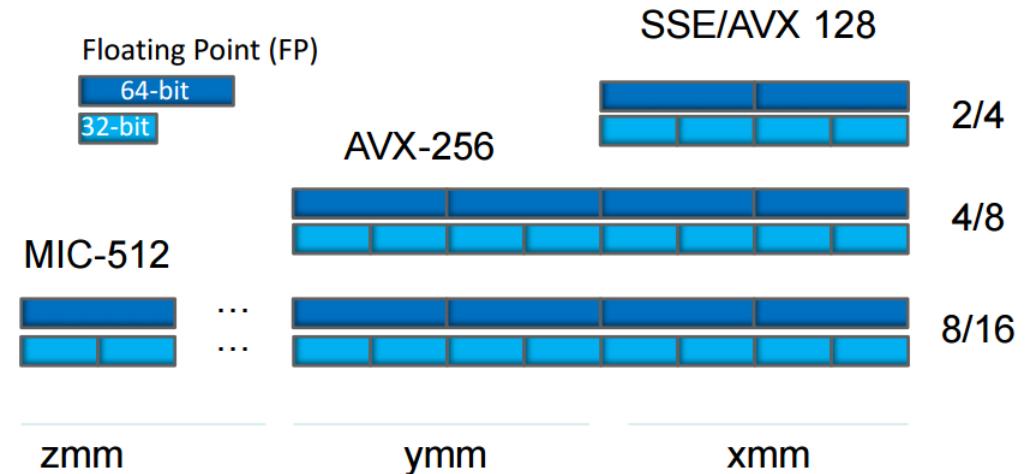
Векторные регистры (SIMD – single instruction multiple data)

- Каждое из 61 ядра имеет модуль векторной обработки (VPU, vector processor unit) – 32 512-разрядных zmm-регистра;
- Одновременные действия над 16 32-битными целыми/вещественными числами или 8 64-битными целыми/вещественными числами
- Большинство операций используют 2 аргумента и один результат



X86 SIMD History

Год	Разрядность (бит)	Набор инструкций
1997	64	MMX
1999	128	SSE
2001	128	SSE2
---	128	SSEx (3-4)
2010	256	AVX
2012	512	KNC(Xeon Phi)
2014	256	AVX2
2015	512	AVX-512



- Архитектура и возможности векторизации Intel Xeon Phi
- **Выравнивание памяти**
 - Программные способы векторизации
 - Интринсики. Типы операций
 - Пример умножения матрицы на вектор
 - Пример умножения «упакованных» матриц
 - Сравнение производительности

Кэш вычислительного ядра Intel® Xeon Phi™

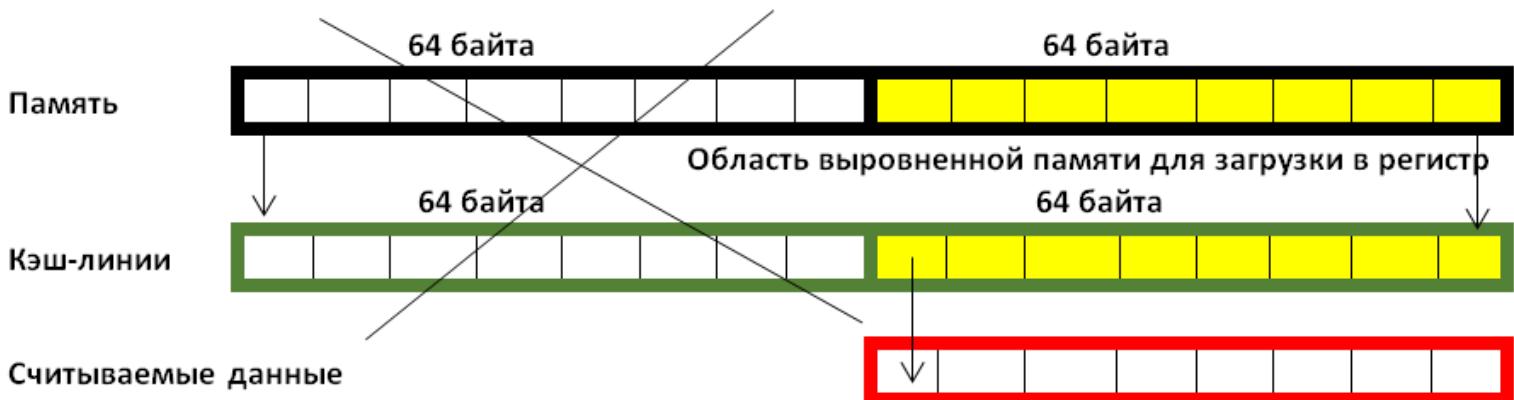
Уровень КЭШа	L1	L2
Размер	32Kb (инструкции) + 32Kb (данные)	512 Kb (под инструкции и данные)
Ассоциативность/Размер линейки/Число банков	8-way/64 Bytes/8	8-way/64 Bytes/8
Идеальное время доступа	1 такт	11 тактов
Среднее время доступа	3 такта	14-15 тактов
Порт	Чтение или запись	Чтение или запись

Выравнивание памяти

Чтение без выравнивания



Чтение с выравниванием



Выровненное выделение памяти

Статический массив

```
_declspec(align(64)) double p[N]
```

Динамический массив

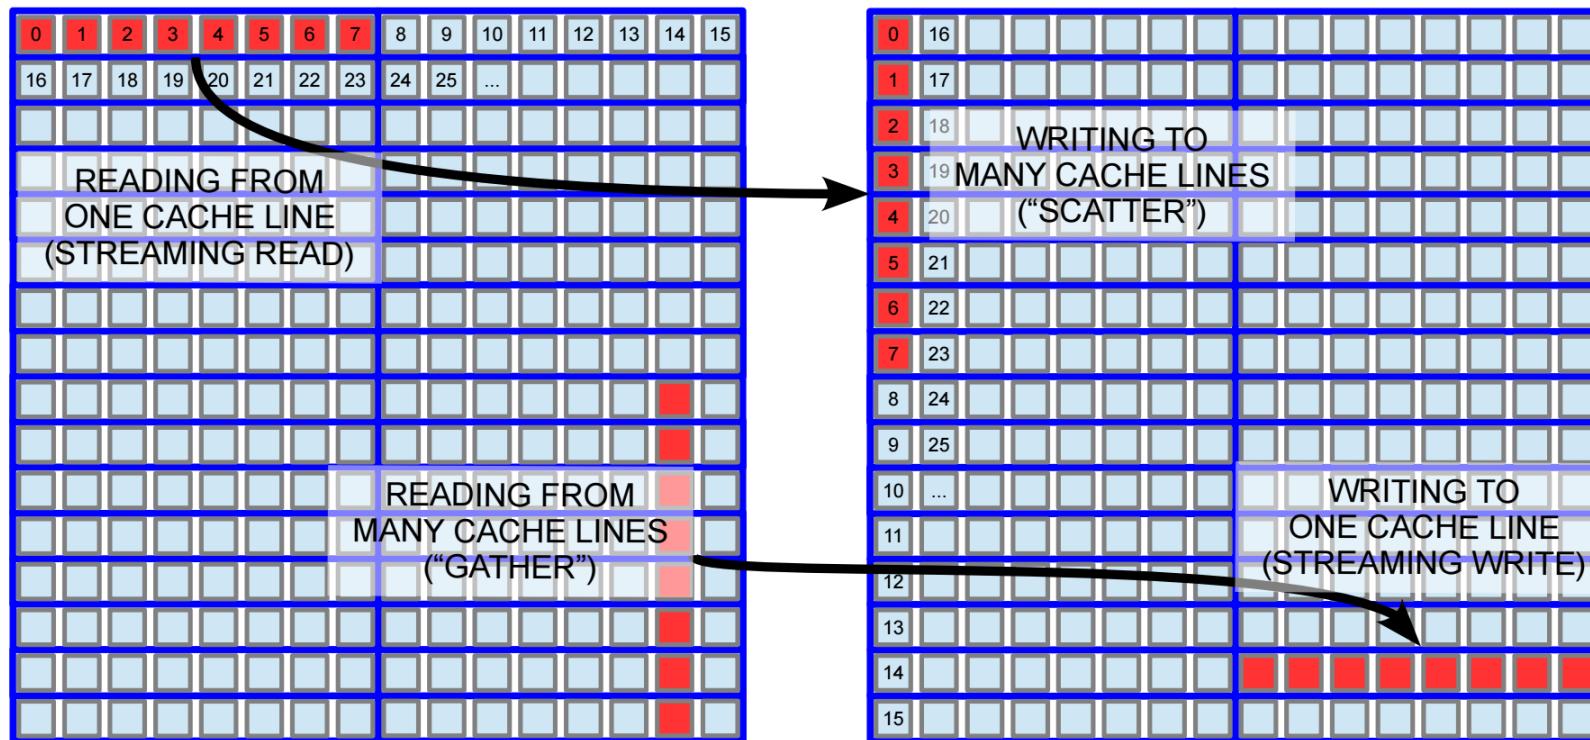
```
double* p = (double*)_mm_malloc(sz, 64);  
_mm_free(p)
```

```
#define N 1024  
_declspec(align(64)) double  
p[N];  
double k = 0;  
for(int i = 0; i < N; i++)  
{  
    k += p[i]  
}
```

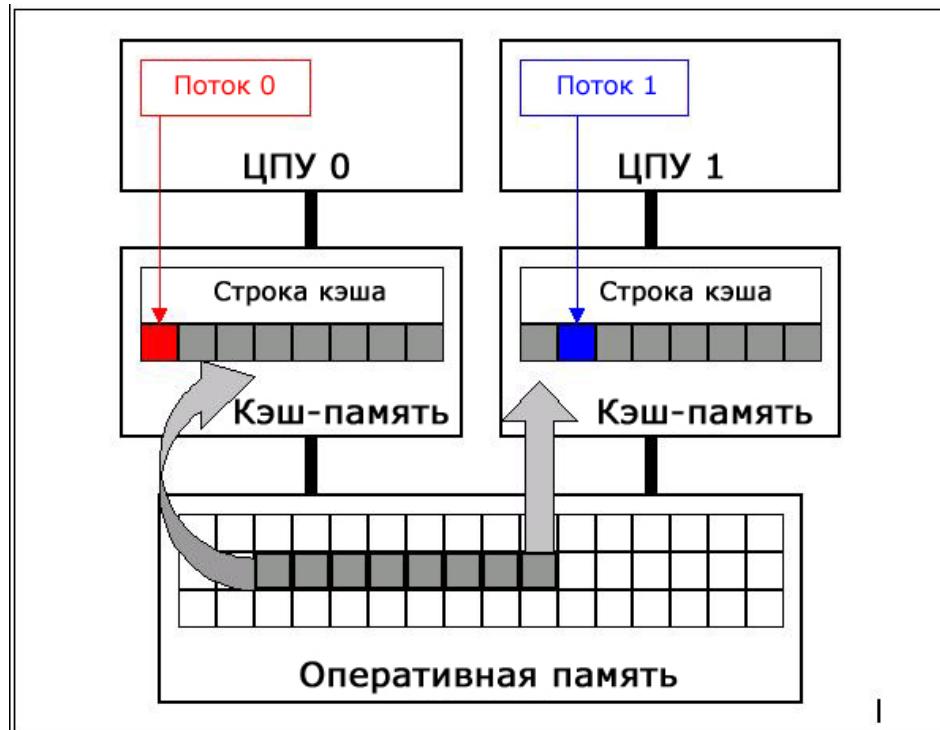
```
#define N 1024  
_declspec(align(64)) double  
p[N];  
double k = 0;  
for(int i = 0; i < N; i+=8)  
{  
    k += p[i]  
}
```

Конфликт доступа к КЭШ-памяти

Пример: транспонирование матрицы



Конфликт доступа к КЭШ-памяти в многопоточном режиме



```
double sum=0.0, sum_local[NUM_THREADS];
#pragma omp parallel
num_threads(NUM_THREADS)
{
    int me = omp_get_thread_num();
    sum_local[me] = 0.0;

#pragma omp for
    for (i = 0; i < N; i++)
        sum_local[me] += x[i] * y[i];

#pragma omp atomic sum += sum_local[me];
}
```

- Архитектура и возможности векторизации Intel Xeon Phi
- Выравнивание памяти
- **Программные способы векторизации**
- Интринсики. Типы операций
- Пример умножения матрицы на вектор
- Пример умножения «упакованных» матриц
- Сравнение производительности

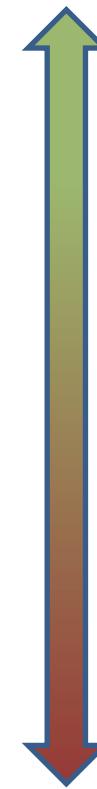
Способы векторизации кода

Автовекторизация

Легко

MIN эффективность

Директивы для векторизации



Intel® Cilk™ Plus Array Notation

Классы SIMD интринсиков (F64Vec8, F32Vec16)

Функции-интринсики(__mm512_mul_pd)

ASSEMBLER (vmulpd zmm {k}, zmm, zmm)

Сложно

MAX эффективность

Директивы компилятора

// Векторизация с явной
длиной вектора 16

```
#pragma simd
vectorlength(16)
for (int i = 0; i < N;
i++)
{
    C[i] = B[i] + C[i];
}
```

// Векторизация с
указанием того, что
данные выровнены

```
#pragma vector aligned
for (int i = 0; i < N;
i++)
{
    C[i] = B[i] + C[i];
}
```

// Векторизация с
игнорированием анализа
эффективности и
указанием игнорировать
зависимости по данным

```
#pragma ivdep
#pragma vector always
for (int i = 0; i < N;
i++)
{
    C[i] = B[i] + C[i];
}
```

Директивы OpenMP

```
void omp_simd (float *A, float *B, float *C)
{
    #pragma omp simd aligned (A, B, C: 64)
    for (int i = 0; i < N; i++)
        C[i] = A[i] + B[i];
}
```

Intel® Cilk™ Plus Array Notation

```
#include <cilk\cilk.h>
void cilk_test(float* a, float* b, float* c)
{
    C[0:n] = A[0:n] + B[0:n];
}
```

Классы SIMD Intrinsic

```
#include <micvec.h>

F64vec8 A[N], B[N], C[N];

for(int i = 0; i < N; i++)
    C[i] = A[i] + B[i];
```

- Архитектура и возможности векторизации Intel Xeon Phi
- Выравнивание памяти
- Программные способы векторизации
- **Интринсики. Типы операций**
- Пример умножения матрицы на вектор
- Пример умножения «упакованных» матриц
- Сравнение производительности

Интриныки. Типы операций

- **Доступ к данным:** загрузка и выгрузка данных
- **Математические операции:** сложение, вычитание, умножение, деление, FMA (для вычислений с плавающей запятой)
- **Вычисление математических функций:** степень, корень, обращение числа, логарифм, модуль
- **Логические операции:** позволяющие выполнять векторные сравнения, находить минимум и максимум и т.д.
- **Операции редукции:** сложение, умножение, минимум, максимум
- **Операции перемешивания и объединения данных**

Программирование и компиляция

- Заголовочные файлы для доступа к функциям-интринсикам для различных наборов SIMD инструкций

```
#include <mmmintrin.h> // MMX  
#include <xmmmintrin.h> //SSE  
#include <emmintrin.h> //SSE2  
#include <pmmmintrin.h> //SSE3  
#include <tmmmintrin.h> //SSSE3  
#include <smmmintrin.h> //SSE4  
#include <avxintrin.h> //AVX  
#include <fmaintrin.h> //FMA
```

```
#include <immintrin.h> // KNC и другие
```

Компилятор Intel, команда для компиляции

```
icc -O2 -mmic test.cpp -std=c++11 -o test.exe  
scp test.exe mic0:~  
ssh mic0  
./test.exe
```

Интринсики. Типы данных

_m512: 16 x float

_m512d: 8 x double

_m512i: 16 x int32 или 8 x int64

_mmask8: 8-битная маска

_mmask16: 16-битная маска

Префикс интринсиков для Intel® Xeon Phi™: _mm512_

Многие операции имеют суффикс для обозначения типов данных:

_mm512_load_ps: загрузка float-вектора

_mm512_load_pd: загрузка double-вектора

_mm512_load_epi32: загрузка целых 32-разрядных чисел

_mm512_load_epi64: загрузка целых 64-разрядных чисел

Операции загрузки и выгрузки данных

- Загрузка

`__m512d _mm512_load_pd (void const* mt)`

`__m512d _mm512_extload_pd (void const* mt,`

`_MM_UPCONV_PD_ENUM conv, _MM_BROADCAST64_ENUM bc, int hint)`

- Выгрузка

`void _mm512_mask_store_pd (void* mem_addr, __mmask8 k, __m512d a)`

`void _mm512_store_pd (void* mem_addr, __m512d a)`

_mm512_extload_pd _MM_BROADCAST64_ENUM

- _MM_BROADCAST64_NONE

память	<table border="1"><tr><td>b_0</td><td>b_1</td><td>b_2</td><td>b_3</td><td>b_4</td><td>b_5</td><td>b_6</td><td>b_7</td></tr></table>	b_0	b_1	b_2	b_3	b_4	b_5	b_6	b_7
b_0	b_1	b_2	b_3	b_4	b_5	b_6	b_7		

регистр	<table border="1"><tr><td>b_0</td><td>b_1</td><td>b_2</td><td>b_3</td><td>b_4</td><td>b_5</td><td>b_6</td><td>b_7</td></tr></table>	b_0	b_1	b_2	b_3	b_4	b_5	b_6	b_7
b_0	b_1	b_2	b_3	b_4	b_5	b_6	b_7		

- _MM_BROADCAST_1X8

память	<table border="1"><tr><td>b_0</td><td>b_1</td><td>b_2</td><td>b_3</td><td>b_4</td><td>b_5</td><td>b_6</td><td>b_7</td></tr></table>	b_0	b_1	b_2	b_3	b_4	b_5	b_6	b_7
b_0	b_1	b_2	b_3	b_4	b_5	b_6	b_7		

регистр	<table border="1"><tr><td>b_0</td><td>b_0</td><td>b_0</td><td>b_0</td><td>b_0</td><td>b_0</td><td>b_0</td><td>b_0</td></tr></table>	b_0							
b_0	b_0	b_0	b_0	b_0	b_0	b_0	b_0		

- _MM_BROADCAST_4X8

память	<table border="1"><tr><td>b_0</td><td>b_1</td><td>b_2</td><td>b_3</td><td>b_4</td><td>b_5</td><td>b_6</td><td>b_7</td></tr></table>	b_0	b_1	b_2	b_3	b_4	b_5	b_6	b_7
b_0	b_1	b_2	b_3	b_4	b_5	b_6	b_7		

регистр	<table border="1"><tr><td>b_0</td><td>b_1</td><td>b_2</td><td>b_3</td><td>b_0</td><td>b_1</td><td>b_2</td><td>b_3</td></tr></table>	b_0	b_1	b_2	b_3	b_0	b_1	b_2	b_3
b_0	b_1	b_2	b_3	b_0	b_1	b_2	b_3		

Инструкции для математических функций

Ускоренное вычисление 2^N (только для одинарной точности)

`__m512_mm512_exp23_ps (__m512i a)`

Ускоренное вычисление \log_2 (только для одинарной точности)

`__m512_mm512_log2_ps (__m512 a)`

Ускоренное обращение числа

`__m512_mm512_rcp23_ps (__m512 a)`

Ускоренное вычисление квадратного корня

`__m512_mm512_rsqrt23_ps (__m512 a)`

Вычисление модуля для одинарной точности

`__m512_mm512_abs_ps (__m512 a)`

Вычисление модуля для двойной точности

`__m512d_mm512_abs_pd (__m512d a)`

Пакетные арифметические инструкции

Сложение

`__m512d _mm512_add_pd (__m512d a, __m512d b)`

Умножение

`__m512d _mm512_mul_pd (__m512d a, __m512d b)`

Сложение с отрицанием

`__m512d _mm512_addn_pd (__m512d a, __m512d b)`

FMA – инструкции (смешанное умножение со сложением)

Смешанное умножение со сложением:

$$d = a * b + c$$

```
__m512d _mm512_fmadd_pd (__m512d a,  
__m512d b, __m512d c)
```

Смешанное умножение с вычитанием:

$$d = a * b - c$$

```
__m512d _mm512_fmsub_pd (__m512d a,  
__m512d b, __m512d c)
```

Операции редукции

- Вычисление минимального числа
`double _mm512_reduce_min_pd (_m512d a)`
- Вычисление максимального числа
`double _mm512_reduce_max_pd (_m512d a)`
- Сложение элементов в регистре
`double _mm512_reduce_add_pd (_m512d a)`
- Умножение элементов в регистре
`double _mm512_reduce_mul_pd (_m512d a)`

Операции сравнения

- Проверка на меньше, либо равно

`__mmask8 _mm512_cple_pd_mask (__m512d a, __m512d b)`

- Проверка на строго больше

`__mmask8 _mm512_cmpnle_pd_mask (__m512d a, __m512d b)`

- Сравнение на равенство

`__mmask8 _mm512_cmpeq_pd_mask (__m512d a, __m512d b)`

- Сравнение на неравенство

`__mmask8 _mm512_cmpneq_pd_mask (__m512d a, __m512d b)`

Операции перемешивания элементов

Смешивание 2 регистров по маске

```
__m512d _mm512_mask_blend_pd (
    __mmask8 k, __m512d a, __m512d b)
```

Перестановка элементов в 4-элементных частях регистра

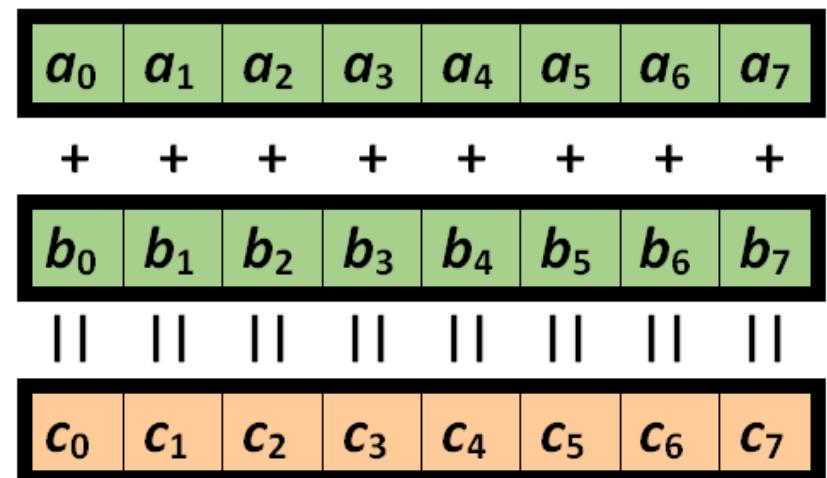
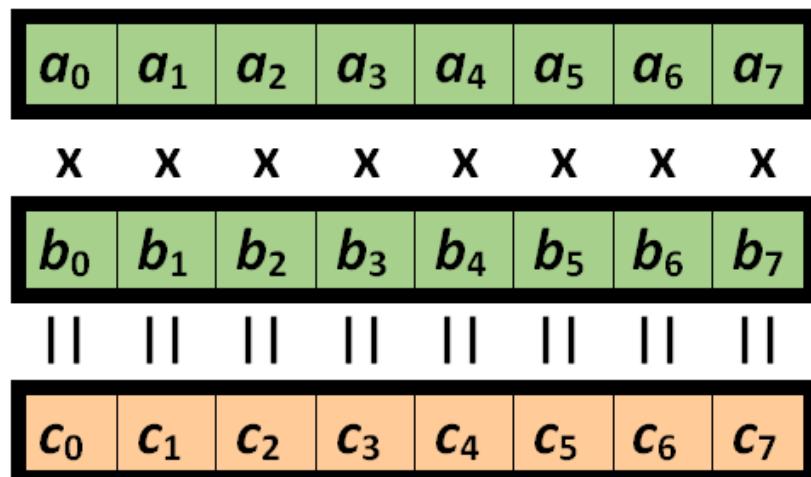
```
__m512d _mm512_swizzle_pd (
    __m512d v, _MM_SWIZZLE_ENUM s)
```

_MM_SWIZZLE_ENUM:

```
_MM_SWIZ_REG_NONE - hgfe dcba
_MM_SWIZ_REG_DCBA - hgfe dcba
_MM_SWIZ_REG_CDAB - ghef cdab
_MM_SWIZ_REG_BADC - fehg badc
_MM_SWIZ_REG_AAAA - eeee aaaa
_MM_SWIZ_REG_BBBB - ffff bbbb
_MM_SWIZ_REG_CCCC - gggg cccc
_MM_SWIZ_REG_DDDD - hhhh dddd
_MM_SWIZ_REG_DACB - hfeg dbac
```

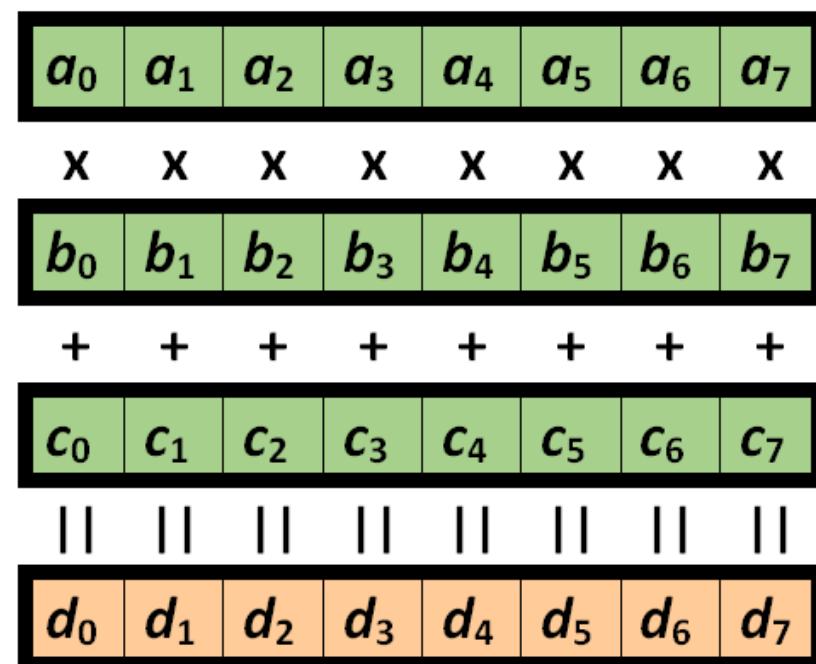
Пакетные операции с двумя операторами

`__m512d _mm512_mul_pd (__m512d a, __m512d b)`
`__m512d _mm512_add_pd (__m512d a, __m512d b)`



Пакетные операции с тремя операторами

`__m512d _mm512_fmadd_pd (__m512d a, __m512d b, __m512d c)`
`__m512d _mm512_fmsub_pd (__m512d a, __m512d b, __m512d c)`

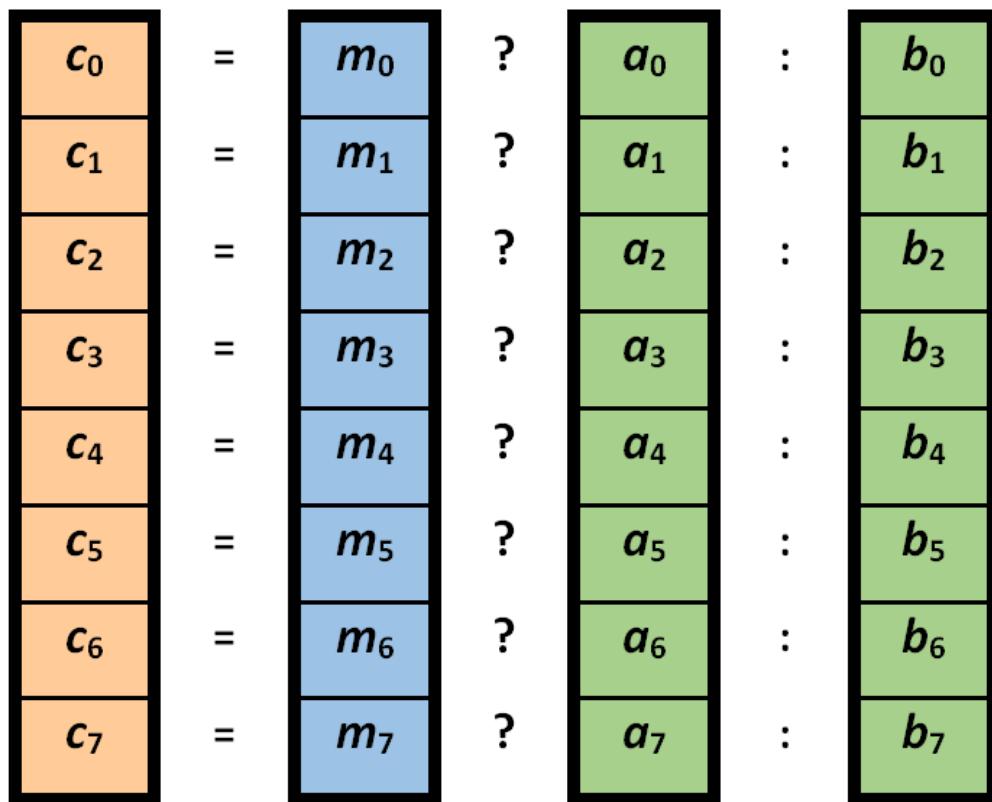


Операции сравнения

__mmask8 _mm512_cmpeq_pd_mask (__m512d a, __m512d b)

m_0	=	a_0	==	b_0	?	1	:	0
m_1	=	a_1	==	b_1	?	1	:	0
m_2	=	a_2	==	b_2	?	1	:	0
m_3	=	a_3	==	b_3	?	1	:	0
m_4	=	a_4	==	b_4	?	1	:	0
m_5	=	a_5	==	b_5	?	1	:	0
m_6	=	a_6	==	b_6	?	1	:	0
m_7	=	a_7	==	b_7	?	1	:	0

`__m512d _mm512_mask_blend_pd (__mmask8 m, __m512d a, __m512d b)`



Пример

a	=	<table border="1"><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td><td>6</td><td>7</td><td>8</td></tr></table>	1	2	3	4	5	6	7	8
1	2	3	4	5	6	7	8			
b	=	<table border="1"><tr><td>8</td><td>7</td><td>6</td><td>5</td><td>4</td><td>3</td><td>2</td><td>1</td></tr></table>	8	7	6	5	4	3	2	1
8	7	6	5	4	3	2	1			
m	=	<table border="1"><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td><td>1</td><td>1</td><td>1</td></tr></table>	0	0	0	0	1	1	1	1
0	0	0	0	1	1	1	1			
c	=	<table border="1"><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>4</td><td>3</td><td>2</td><td>1</td></tr></table>	1	2	3	4	4	3	2	1
1	2	3	4	4	3	2	1			

- Архитектура и возможности векторизации Intel Xeon Phi
- Выравнивание памяти
- Программные способы векторизации
- Интринсики. Типы операций
- **Пример умножения матрицы на вектор**
- Пример умножения «упакованных» матриц
- Сравнение производительности

Умножение матрицы на вектор

$$\mathbf{b} = A^T \times \mathbf{a}$$

$$b_0 = A_{00}a_0 + A_{10}a_1 + A_{20}a_2 + A_{30}a_3$$

$$b_1 = A_{01}a_0 + A_{11}a_1 + A_{21}a_2 + A_{31}a_3$$

$$b_2 = A_{02}a_0 + A_{12}a_1 + A_{22}a_2 + A_{32}a_3$$

$$b_3 = A_{03}a_0 + A_{13}a_1 + A_{23}a_2 + A_{33}a_3$$

Хранение матрицы по строкам:

$$A = [A_{00}, A_{01}, A_{02}, A_{03}, A_{10}, A_{11}, A_{12}, A_{13}, A_{20}, A_{21}, A_{22}, A_{23}, A_{30}, A_{31}, A_{32}, A_{33}]$$

Код загрузки данных в регистры для матрицы 16x16

```
zmm00 = _mm512_load_ps(mtx);
zmm01 = _mm512_load_ps(mtx + VECTOR_SIZE);
zmm02 = _mm512_load_ps(mtx + VECTOR_SIZE * 2);
zmm03 = _mm512_load_ps(mtx + VECTOR_SIZE * 3);
zmm04 = _mm512_load_ps(mtx + VECTOR_SIZE * 4);
zmm05 = _mm512_load_ps(mtx + VECTOR_SIZE * 5);
zmm06 = _mm512_load_ps(mtx + VECTOR_SIZE * 6);
zmm07 = _mm512_load_ps(mtx + VECTOR_SIZE * 7);
zmm08 = _mm512_load_ps(mtx + VECTOR_SIZE * 8);
zmm09 = _mm512_load_ps(mtx + VECTOR_SIZE * 9);
zmm10 = _mm512_load_ps(mtx + VECTOR_SIZE * 10);
zmm11 = _mm512_load_ps(mtx + VECTOR_SIZE * 11);
zmm12 = _mm512_load_ps(mtx + VECTOR_SIZE * 12);
zmm13 = _mm512_load_ps(mtx + VECTOR_SIZE * 13);
zmm14 = _mm512_load_ps(mtx + VECTOR_SIZE * 14);
zmm15 = _mm512_load_ps(mtx + VECTOR_SIZE * 15);
...
zmm16 = _mm512_extload_ps(vec, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm17 = _mm512_extload_ps(vec + 1, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm18 = _mm512_extload_ps(vec + 2, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm19 = _mm512_extload_ps(vec + 3, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm20 = _mm512_extload_ps(vec + 4, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm21 = _mm512_extload_ps(vec + 5, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm22 = _mm512_extload_ps(vec + 6, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm23 = _mm512_extload_ps(vec + 7, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm24 = _mm512_extload_ps(vec + 8, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm25 = _mm512_extload_ps(vec + 9, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm26 = _mm512_extload_ps(vec + 10, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm27 = _mm512_extload_ps(vec + 11, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm28 = _mm512_extload_ps(vec + 12, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm29 = _mm512_extload_ps(vec + 13, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm30 = _mm512_extload_ps(vec + 14, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
zmm31 = _mm512_extload_ps(vec + 15, _MM_UPCONV_PS_NONE, _MM_BROADCAST_1X16, _MM_HINT_NONE);
```

Код вычисления и выгрузки результата

```
zmm00 = _mm512_mul_ps(zmm00, zmm16);
zmm00 = _mm512_fmadd_ps(zmm01, zmm17, zmm00);
zmm00 = _mm512_fmadd_ps(zmm02, zmm18, zmm00);
zmm00 = _mm512_fmadd_ps(zmm03, zmm19, zmm00);
zmm00 = _mm512_fmadd_ps(zmm04, zmm20, zmm00);
zmm00 = _mm512_fmadd_ps(zmm05, zmm21, zmm00);
zmm00 = _mm512_fmadd_ps(zmm06, zmm22, zmm00);
zmm00 = _mm512_fmadd_ps(zmm07, zmm23, zmm00);
zmm00 = _mm512_fmadd_ps(zmm08, zmm24, zmm00);
zmm00 = _mm512_fmadd_ps(zmm09, zmm25, zmm00);
zmm00 = _mm512_fmadd_ps(zmm10, zmm26, zmm00);
zmm00 = _mm512_fmadd_ps(zmm11, zmm27, zmm00);
zmm00 = _mm512_fmadd_ps(zmm12, zmm28, zmm00);
zmm00 = _mm512_fmadd_ps(zmm13, zmm29, zmm00);
zmm00 = _mm512_fmadd_ps(zmm14, zmm30, zmm00);
zmm00 = _mm512_fmadd_ps(zmm15, zmm31, zmm00);
_mm512_store_ps(res, zmm00);
```

- Архитектура и возможности векторизации Intel Xeon Phi
- Выравнивание памяти
- Программные способы векторизации
- Интринсики. Типы операций
- Пример умножения матрицы на вектор
- **Пример умножения «упакованных» матриц**
- Сравнение производительности

Умножение упакованных матриц на вектора

Умножение матриц 4x4 на вектора 4x1

$$\begin{array}{|c|} \hline R1 \\ \hline R2 \\ \hline R3 \\ \hline R4 \\ \hline \end{array} = \begin{array}{|c|} \hline A^T \\ \hline B^T \\ \hline C^T \\ \hline D^T \\ \hline \end{array} \times \begin{array}{|c|} \hline V1 \\ \hline V2 \\ \hline V3 \\ \hline V4 \\ \hline \end{array}$$

$$\begin{array}{|c|} \hline R9 \\ \hline R10 \\ \hline R11 \\ \hline R12 \\ \hline \end{array} = \begin{array}{|c|} \hline I^T \\ \hline J^T \\ \hline K^T \\ \hline L^T \\ \hline \end{array} \times \begin{array}{|c|} \hline V9 \\ \hline V10 \\ \hline V11 \\ \hline V12 \\ \hline \end{array}$$

$$\begin{array}{|c|} \hline R5 \\ \hline R6 \\ \hline R7 \\ \hline R8 \\ \hline \end{array} = \begin{array}{|c|} \hline E^T \\ \hline F^T \\ \hline G^T \\ \hline H^T \\ \hline \end{array} \times \begin{array}{|c|} \hline V5 \\ \hline V6 \\ \hline V7 \\ \hline V8 \\ \hline \end{array}$$

$$\begin{array}{|c|} \hline R13 \\ \hline R14 \\ \hline R15 \\ \hline R16 \\ \hline \end{array} = \begin{array}{|c|} \hline M^T \\ \hline N^T \\ \hline J^T \\ \hline P^T \\ \hline \end{array} \times \begin{array}{|c|} \hline V13 \\ \hline V14 \\ \hline V15 \\ \hline V16 \\ \hline \end{array}$$

Упаковка матриц 4x4
в матрицу 16x16

A	B	C	D
E	F	G	H
I	J	K	L
M	N	O	P

Расположение элементов в памяти

- Элементы векторов хранятся последовательно
 - Строки матриц хранятся по порядку для каждого из 4 матриц: сначала четыре первые строки, потом вторые, третьи и четвертые

Код загрузки данных

```
const int N = 4;
const int mask32_0 = 0x00F0;
const int mask32_1 = 0xF000;
const int mask32_2 = 0xFF00;
for (int i = 0; i < N; i++)
{
    REAL* vec = invec + i * VECTOR_SIZE;
    REAL* mtx = inmtx + i * VECTOR_SIZE * N;
    zmm00 = _mm512_load_ps(inmtx);
    zmm01 = _mm512_load_ps(inmtx + VECTOR_SIZE);
    zmm02 = _mm512_load_ps(inmtx + VECTOR_SIZE * 2);
    zmm03 = _mm512_load_ps(inmtx + VECTOR_SIZE * 3);
    ...
    ...
    zmm08 = _mm512_extload_ps(vec + 0, _MM_UPCONV_PS_NONE,
                               _MM_BROADCAST_1X16, _MM_HINT_NONE);
    zmm09 = _mm512_extload_ps(vec + 4, _MM_UPCONV_PS_NONE,
                               _MM_BROADCAST_1X16, _MM_HINT_NONE);
    zmm10 = _mm512_extload_ps(vec + 8, _MM_UPCONV_PS_NONE,
                               _MM_BROADCAST_1X16, _MM_HINT_NONE);
    zmm11 = _mm512_extload_ps(vec + 12, _MM_UPCONV_PS_NONE,
                               _MM_BROADCAST_1X16, _MM_HINT_NONE);
    zmm12 = _mm512_extload_ps(vec + 1, _MM_UPCONV_PS_NONE,
                               _MM_BROADCAST_1X16, _MM_HINT_NONE);
    zmm13 = _mm512_extload_ps(vec + 5, _MM_UPCONV_PS_NONE,
                               _MM_BROADCAST_1X16, _MM_HINT_NONE);
    zmm14 = _mm512_extload_ps(vec + 9, _MM_UPCONV_PS_NONE,
                               _MM_BROADCAST_1X16, _MM_HINT_NONE);
    zmm15 = _mm512_extload_ps(vec + 13, _MM_UPCONV_PS_NONE,
                               _MM_BROADCAST_1X16, _MM_HINT_NONE);

    zmm06 = _mm512_mask_blend_ps(mask32_0, zmm08, zmm09);
    zmm07 = _mm512_mask_blend_ps(mask32_1, zmm10, zmm11);
    zmm04 = _mm512_mask_blend_ps(mask32_2, zmm06, zmm07);
    zmm06 = _mm512_mask_blend_ps(mask32_0, zmm12, zmm13);
    zmm07 = _mm512_mask_blend_ps(mask32_1, zmm14, zmm15);
    zmm05 = _mm512_mask_blend_ps(mask32_2, zmm06, zmm07);
    ...
}
```

Код вычисления и выгрузки результатов

```
for (int i = 0; i < N; i++)
{
    ... Код загрузки и подготовки данных ...
    zmm16 = _mm512_mul_ps(zmm00, zmm04);
    zmm16 = _mm512_fmadd_ps(zmm01, zmm05, zmm16);
    zmm16 = _mm512_fmadd_ps(zmm02, zmm06, zmm16);
    zmm16 = _mm512_fmadd_ps(zmm03, zmm07, zmm16);

    _mm512_store_ps(res+i*16, zmm16);
}
```

Оптимальная версия кода с использованием SWIZZLE

```
const int N = 4;
for (int i = 0; i < N; i++)
{
    REAL* vec = invec + i * VECTOR_SIZE;
    REAL* mtx = inmtx + i * VECTOR_SIZE * N;
    zmm00 = _mm512_load_ps(inmtx);
    zmm01 = _mm512_load_ps(inmtx + VECTOR_SIZE);
    zmm02 = _mm512_load_ps(inmtx + VECTOR_SIZE * 2);
    zmm03 = _mm512_load_ps(inmtx + VECTOR_SIZE * 3);
    zmm08 = _mm512_load_ps(vec);
    zmm04 = _mm512_swizzle_ps(zmm08, _MM_SWIZ_REG_AAAA);
    zmm05 = _mm512_swizzle_ps(zmm08, _MM_SWIZ_REG_BBBB);
    zmm06 = _mm512_swizzle_ps(zmm08, _MM_SWIZ_REG_CCCC);
    zmm07 = _mm512_swizzle_ps(zmm08, _MM_SWIZ_REG_DDDD);
    zmm16 = _mm512_mul_ps(zmm00, zmm04);
    zmm16 = _mm512_fmadd_ps(zmm01, zmm05, zmm16);
    zmm16 = _mm512_fmadd_ps(zmm02, zmm06, zmm16);
    zmm16 = _mm512_fmadd_ps(zmm03, zmm07, zmm16);
    _mm512_store_ps(res+i*16, zmm16);
}
```

- Архитектура и возможности векторизации Intel Xeon Phi
- Выравнивание памяти
- Программные способы векторизации
- Интринсики. Типы операций
- Пример умножения матрицы на вектор
- Пример умножения «упакованных» матриц
- **Сравнение производительности**

Сравнение производительности

– Умножение матриц на вектор

	t auto	t auto loop inv	t simd	s loop inv	s simd
float	4.16	1	0.75	4.16	5.55
double	5.77	3.1	1.6	1.86	3.61

– Умножение упакованных матриц на вектор

	t auto	t simd blend	t simd swizzle	s simd blend	s simd swizzle
float	1.15	0.34	0.2	3.38	5.75
double	1.41	0.55	0.45	2.56	3.13

Основные выводы

- Векторизация кода с помощью функций-интринсиков позволяет в ряде случаев получить выигрыш производительности по сравнению с автоматической векторизацией
- Ручная векторизация требует особой организации данных в памяти и использования выровненной памяти
- Количество регистров ограничено, но повторная загрузка данных в регистры замедляет программу, поэтому надо использовать максимально доступное число регистров (32 для Intel Xeon Phi)
- При работе в многопоточном режиме необходимо следить за отсутствием конфликтов доступа к кэш-памяти и разделять задачу по расположению данных в памяти

Ссылки

Achieving Superior Performance on Black-Scholes Valuation Computing using Intel® Xeon Phi™ Coprocessors

<https://software.intel.com/en-us/articles/case-study-achieving-superior-performance-on-black-scholes-valuation-computing-using>

Intel® Xeon Phi™ Core Micro-architecture

<https://software.intel.com/en-us/articles/intel-xeon-phi-core-micro-architecture>

Intel® Intrinsic Guide

<https://software.intel.com/sites/landingpage/IntrinsicsGuide/>

Спасибо за внимание

<http://www.singularis-lab.com/>



SINGULARIS LAB
software development