Нижегородский государственный университет им. Н.И.Лобачевского

Факультет Вычислительной математики и кибернетики

Программирование для Intel Xeon Phi

Оптимизация прикладных программ для Intel Xeon Phi с использованием Intel C/C++ Compiler. Векторизация

Сиднев А.А.

Архангельск, 2014

Содержание

- Векторизация циклов компилятором. Использование директив
  - Использование ключевого слова restrict
  - Использование #pragma ivdep
  - Использование #pragma simd
- Использование Array notation
- Использование элементарных функций
- Векторизация циклов с вызовами математических функций
- Более сложные примеры векторизации
- Дополнительные задания и литература

Цели

- Изучение средств векторизации кода на Intel Xeon Phi.
- Освоение средств диагностики и различных механизмов векторизации на простом примере.
- Изучение способов векторизации вызовов математических функций.
- Рассмотрение более сложных случаев векторизации, возникающих в прикладной задаче.

Введение

- Рассмотрим простой цикл

```
for (int i = 0; i < n; i++)
    c[i] = a[i] + b[i];
```

a	1.25	2.25	2.0	1.0
		+		
b	2.0	1.15	1.25	2.0
		=		
c	3.25	3.4	3.25	3.0

Введение

- Рассмотрим простой цикл

```
for (int i = 0; i < n; i++)
    c[i] = a[i] + b[i];
```

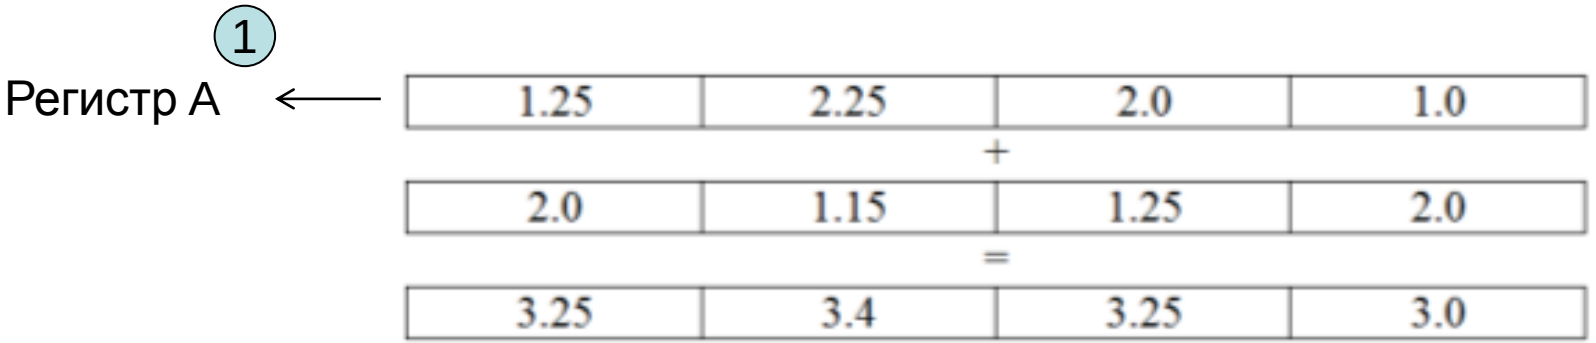

Введение

- Рассмотрим простой цикл

```
for (int i = 0; i < n; i++)
    c[i] = a[i] + b[i];
```

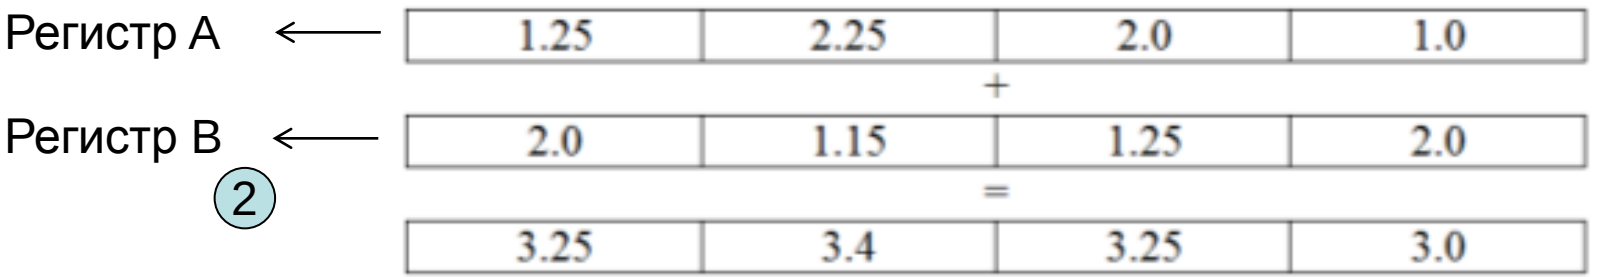

Введение

- Рассмотрим простой цикл

```
for (int i = 0; i < n; i++)
    c[i] = a[i] + b[i];
```

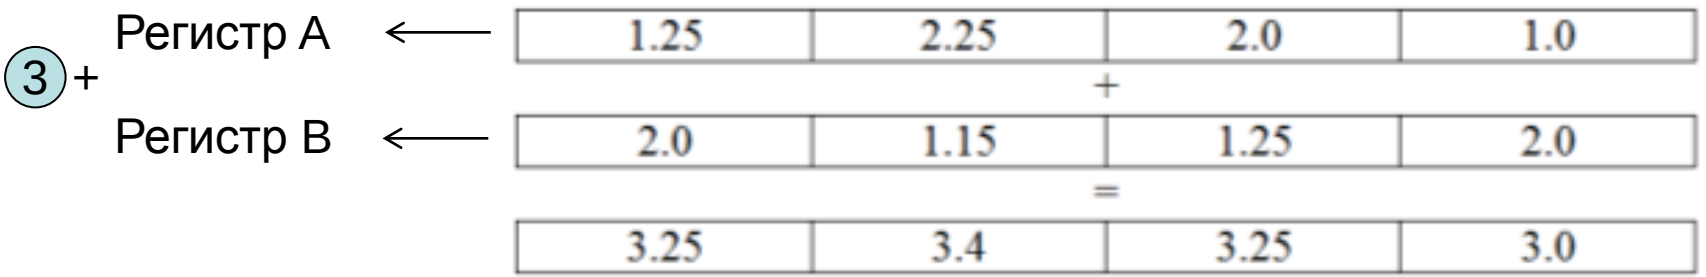

Введение

- Рассмотрим простой цикл

```
for (int i = 0; i < n; i++)
    c[i] = a[i] + b[i];
```

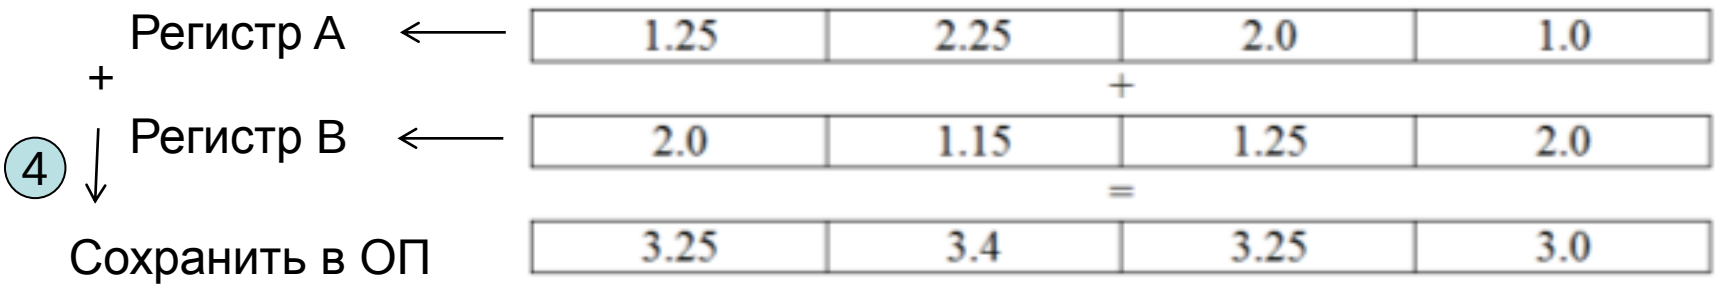

Введение

- Рассмотрим простой цикл

```
for (int i = 0; i < n; i++)
    c[i] = a[i] + b[i];
```

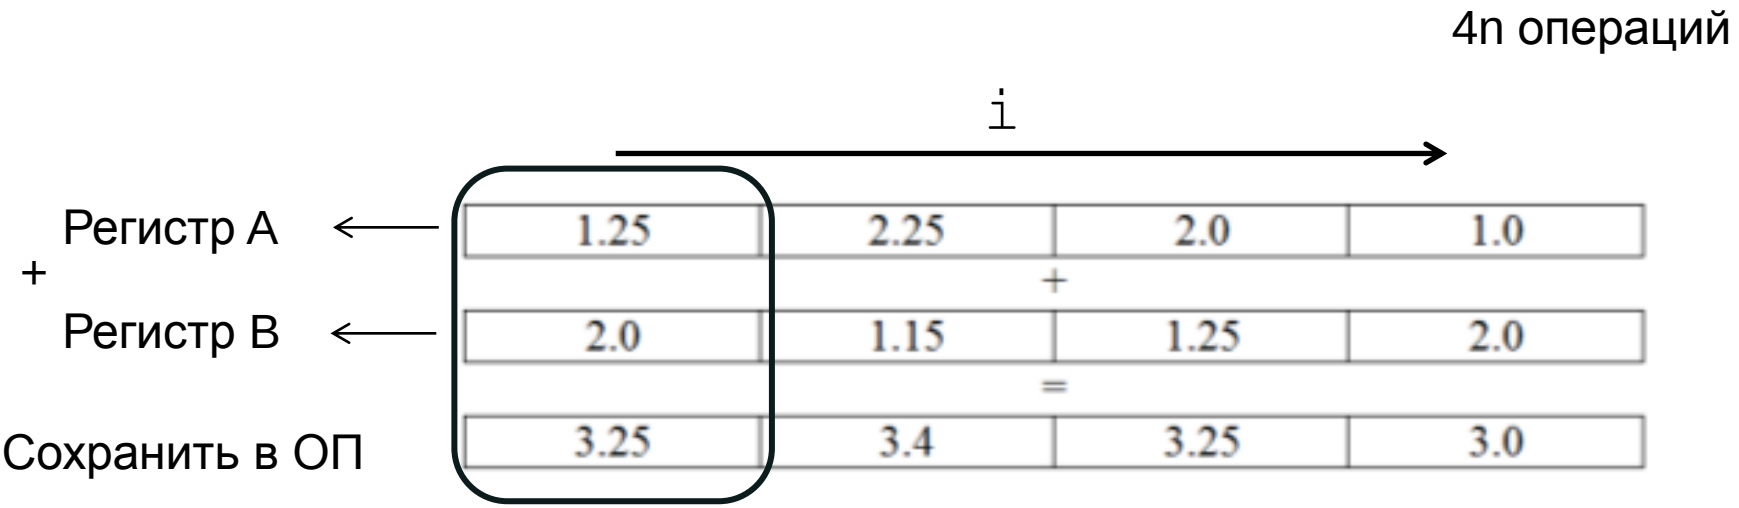

Введение

- Рассмотрим простой цикл

```
for (int i = 0; i < n; i++)
    c[i] = a[i] + b[i];
```

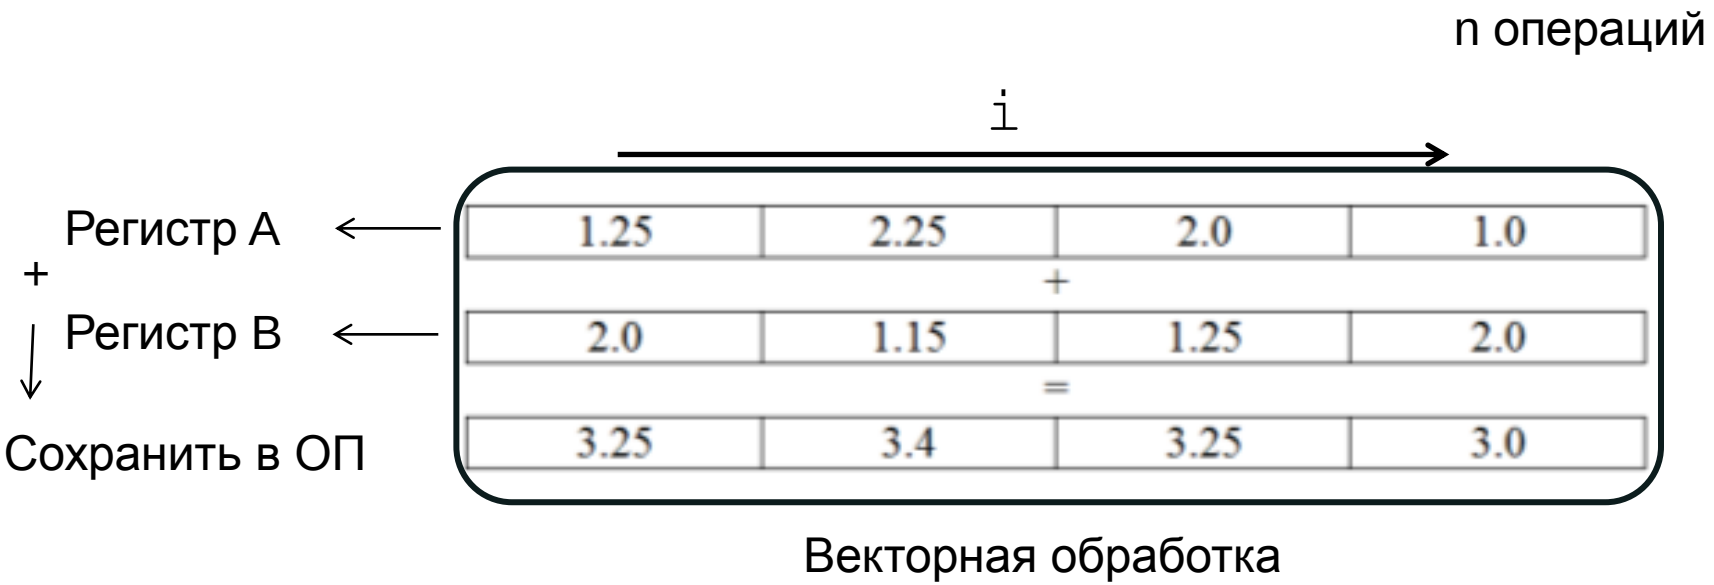

Векторная обработка

Векторные расширения

- Парадигма **SIMD** – single instruction multiple data
- MMX, SSE, SSE2, SSE3…, SSE4, AVX, векторные расширения Intel Xeon Phi
- Основные характеристики
  - Длина векторного регистра
  - Поддерживаемые типы данных
  - Поддерживаемый набор операций

Способы векторизации

1. Использовать высокопроизводительные специализированные библиотеки, эффективно использующие векторные инструкции.
2. Написать программу на C/C++ или Fortran и откомпилировать ее тем транслятором, который «знает» про соответствующие наборы команд.
3. Использовать специальные ключи и директивы компилятора (подсказки).
4. Использовать возможности Array Notation и Elemental Function в рамках технологии Intel Cilk Plus.
5. Использовать классы интринсиков для SIMD.
6. Использовать векторные функции-интринсики.
7. Написать реализацию на ассемблере.

Пример

- Рассмотрим следующий код:

```
void vectorization_simple(float* a, float* b,
     float* c, float* d, int n)
{
    for (int i = 0; i < n; i++)
    {
        a[i] = b[i] * c[i];
        c[i] = a[i] + b[i] - d[i];
    }
}
```

- Итерации цикла независимы? Векторизация возможна?

Пример

```
int main() {
    int n = 10000;
    float* a = new float[n]; float* b = new float[n];
    float* c = new float[n]; float* d = new float[n];
    for (int i = 0; i < n; ++i)
        a[i] = b[i] = c[i] = d[i] = (float)i;
    #pragma noinline
    vectorization_simple(a, b, c, d, n);
    delete[] a;     delete[] b;
    delete[] c;      delete[] d;
    return 0;
}
```

Диагностика векторизации

- В компиляторе Intel есть возможность вывода отчета о векторизации.
- Компиляция с ключом **-vec-report[n]**
  - Вместо [n] число, определяющее степень подробности отчета: чем больше число, тем более подробный отчет.
  - В данной лабораторной работе будет использоваться 3-й уровень подробности, обычно дающий достаточное количество информации (**-vec-report3**).
- Строка компиляции с выводом отчета в файл report.txt:

```
icc -O2 *.cpp –mmic –o vectorization_simple
–vec-report3 &> report.txt
```

Отчет о векторизации

main.cpp(10): (col. 5) remark: LOOP WAS VECTORIZED

main.cpp(10): (col. 5) remark: PEEL LOOP WAS VECTORIZED

main.cpp(10): (col. 5) remark: REMAINDER LOOP WAS VECTORIZED

vectorization_simple.cpp(5): (col. 5) remark: loop was not vectorized: existence of vector dependence

vectorization_simple.cpp(8): (col. 1) remark: vector dependence: assumed FLOW dependence between c line 8 and b line 7

…

vectorization_simple.cpp(8): (col. 1) remark: vector dependence: assumed OUTPUT dependence between c line 8 and a line 7

Зависимости по данным

- ANTI (write after read)

```
   =a
a=
```

```
for
  a[i-1]=a[i] + 1
```

- OUTPUT (write after write)

```
a=
a=
```

```
for
  a[i]=f()
  a[i+1]=g()
```

- FLOW (read after write)

```
a=
   =a
```

```
a[0]=0
for
  a[i]=a[i-1] + 1
```

Выводы из отчета о векторизации

- Был векторизован только цикл с инициализацией массивов (**LOOP WAS VECTORIZED)**.
- Основной цикл в фукнции **vectorization_simple** не был векторизован из-за наличия зависимости по данным между итерациями (**remark: loop was not vectorized: existence of vector dependence).**
- В отчете о векторизации приведено перечисление обнаруженных зависимостей.

Анализ возможности векторизации

- В чем причина обнаруженных компилятором зависимостей?
- На первый взгляд результат кажется неожиданным:
  - цикл является очень простым,
  - итерации «очевидно» независимы,
  - тем не менее, векторизация не была произведена компилятором.
- Удивление может вызвать и огромный список обнаруженных зависимостей в отчете о векторизации.
- Разберемся, в чем причина обнаруженных зависимостей и действительно ли они существуют.

Анализ возможности векторизации

- Компилятор не имеет права произвести некорректную векторизацию цикла.
- При векторизации делаются лишь преобразования, для которых доказана эквивалентность.
- В связи с этим компилятор вынужден быть очень консервативным и любая возможная зависимость является препятствием для векторизации.
- В рассматриваемой функции нет информации о том, как соотносятся указатели **a**, **b**, **c**, **d**.
- Например, если **b**[1] и **a**[0] расположены по одному и тому же адресу в памяти, то при векторном исполнении итераций 0 и 1 результат будет некорректен (отличаться от результата невекторизованного исполнения цикла).

Анализ возможности векторизации

- В то же время программист может обладать информацией о том, что массивы **a**, **b**, **c**, **d** никогда не пересекаются.
- В таком случае обнаруженная компилятором зависимость потенциально возможна, но на самом деле никогда не осуществляется.
- Существует несколько возможностей предоставить компилятору дополнительную информацию или гарантии отсутствия зависимости и, таким образом, способствовать векторизации.
- Рассмотрим данные возможности.

Векторизация циклов компилятором. Использование директив

Использование ключевого слова restrict

- Одним из способов предоставления гарантии того, что указатели не пересекаются, является использование ключевого слова **restrict** (добавлено в стандарте C99).
- Функция с использованием restrict имеет следующий вид:

```
void vectorization_restrict(float* restrict a,
        float* restrict b, float* restrict c,
        float* restrict d, int n) {
    for (int i = 0; i < n; i++) {
        a[i] = b[i] * c[i];
        c[i] = a[i] + b[i] - d[i];
    }
}
```

Использование ключевого слова restrict

- Для компиляции с поддержкой ключевого слова restrict необходимо добавить ключ **–restrict**.
- В этом случае компилятор имеет гарантию отсутствия зависимостей, которые ранее препятствовали векторизации.
- Отчет о векторизации для данной версии подтверждает, что векторизация была успешно произведена:

vectorization_restrict.cpp(5): (col. 5) remark: LOOP WAS VECTORIZED

vectorization_restrict.cpp(5): (col. 5) remark: PEEL LOOP WAS VECTORIZED

vectorization_restrict.cpp(5): (col. 5) remark: REMAINDER LOOP WAS VECTORIZED

Использование #pragma ivdep

- Использование ключевого слова **restrict** дает гарантию, что данные указатели не могут пересекаться.
- Другим способом предоставления компилятору дополнительной информации является директива компилятора **#pragma ivdep** (ivdep – сокращение от ignore vector dependencies).
- Ее использование изменяет способ принятия решения о возможности векторизации данного цикла:
  - компилятор по-прежнему анализирует все возможные зависимости между данными,
  - недоказанные зависимости не принимаются во внимание (считаются несуществующими).

Использование #pragma ivdep

- Если существование зависимости доказано, то векторизация произведена не будет, но все недоказанные зависимости более не будут препятствием для векторизации.
- Функция с #pragma ivdep:

```
void vectorization_ivdep(float* a, float* b,
            float* c, float* d, int n) {
    #pragma ivdep
    for (int i = 0; i < n; i++) {
        a[i] = b[i] * c[i];
        c[i] = a[i] + b[i] - d[i];
    }
}
```

Использование #pragma ivdep

- Векторизация цикла производится успешно, что подтверждается отчетом:

vectorization_ivdep.cpp(6): (col. 5) remark: LOOP WAS VECTORIZED

vectorization_ivdep.cpp(6): (col. 5) remark: PEEL LOOP WAS VECTORIZED

vectorization_ivdep.cpp(6): (col. 5) remark: REMAINDER LOOP WAS VECTORIZED

Использование #pragma simd

- Директива **#pragma ivdep** является относительно традиционным способом помощи компилятору при векторизации.
- Его суть состоит в предоставлении дополнительной информации, на основе которой компилятор может принять более качественное решение о векторизации.
- В некотором смысле, это является косвенным, хотя и весьма мощным, средством векторизации.
- **#pragma simd** представляет другой, новый механизм векторизации. Он дает компилятору явное указание произвести векторизацию данного цикла.

Использование #pragma simd

- Использование для рассматриваемой функции:

```
void vectorization_simd(float* a, float* b,
     float* c, float* d, int n)
{
    #pragma simd
    for (int i = 0; i < n; i++) {
        a[i] = b[i] * c[i];
        c[i] = a[i] + b[i] - d[i];
    }
}
```

- Цикл успешно векторизуется.

#pragma simd

- Используйте **#pragma simd** осторожно!

```
    int n = 100;
    float* a = new float[n];
    a[0] = 0;
#pragma simd
    for (int i = 1; i < n; i++)
        a[i] = a[i - 1] + i;
    std::cout << a[n - 1];
    delete[] a;
```

Использование Array notation

Array notation

- Иногда специфика алгоритма позволяет в явном виде записать его как последовательность операций над векторами.
- В этом случае использование расширения Intel Cilk Plus под названием **Array notation** позволяет получить высокую производительность и, в частности, автоматически векторизовать код.
- Расширение **Array notation** позволяет записывать выражения и операции, исполняемые над несколькими элементами вектора, без написания цикла.

Array notation. Операция “:”

- Вводится операция :, при ее использовании в индексе соответствующая операция применяется ко всем элементам указанного диапазона.
- В общем случае выражения имеют вид: A[start_index : length], где первый параметр обозначает начальный индекс, а второй – количество элементов.
- Если оба параметра опущены, подразумевается весь массив.
- Пример: сложение векторов

```
float A[100], B[100], C[100];
A[:] = B[:] + C[:];
```

Использование Array notation

```
#include <cilk/cilk.h>
void vectorization_array(float* a, float* b,
        float* c, float* d, int n)
{
    a[0:n] = b[0:n] * c[0:n];
    c[0:n] = a[0:n] + b[0:n] - d[0:n];
}
```

- Данный код будет автоматически векторизован.
- Использование Array notation может приводить к повышению производительности и из-за лучшей оптимизации кода.

Использование элементарных функций

Элементарные функции

- Одним из требований для автоматической векторизации кода является отсутствие вызовов функций внутри векторизованного кода (не считая функций, встроенных компилятором).
- В некоторых ситуациях не получается обеспечить автоматическое встраивание, например, из-за сложной структуры или большого объема функции.
- Ручное встраивание сложных функций часто нежелательно с точки зрения качества кода и удобства поддержки.
- В этом случае для векторизации кода можно использовать механизм **элементарных функций** (**Elemental functions**) из Intel Cilk Plus.

Использование элементарных функций

- Векторизуемая операция выносится в функцию со специальной нотацией **__declspec(vector)**.
- В теле функции выполняются операции над одним элементом данных, а сама функция может вызываться для нескольких элементов данных одновременно при векторном исполнении цикла.

Использование элементарных функций

- В рассматриваемом примере создадим элементарную функцию, выполняющую одну итерацию цикла:

```
#include <cilk/cilk.h>
__declspec(vector) void f(float* a, float* b,
          float* c, float* d, int n, int i) {
    a[i] = b[i] * c[i];
    c[i] = a[i] + b[i] - d[i];
}
void vectorization_elemental(float* a, float* b,
           float* c, float* d, int n) {
    for (int i = 0; i < n; i++)
        f(a, b, c, d, n, i);
}
```

Векторизация циклов с вызовами математических функций

Пример

- Рассмотрим цикл с вычислением экспоненты:

```
void exp_loop(float* a, float* b, float* c,
              float* d, int n) {
    #pragma ivdep
    for (int i = 0; i < n; i++)
        a[i] = b[i] + c[i] + expf(d[i]);
}
```

- Отчет о векторизации показывает, что цикл векторизуется.
- Однако в процессоре нет векторных команд для вычисления экспоненты (в отличие от векторных команд для сложения или умножения).
- Тогда каким образом была произведена векторизация?

SVML

- Компиляторы Intel содержат библиотеку реализаций математических функций для короткого вектора аргументов **SVML** (short vector math library).
- В случае векторизации цикла компилятор вставляет вызовы функций SVML.
- Если по каким-то причинам цикл не векторизуется, то вставляются вызовы обычных реализаций из скалярной библиотеки математических функций **LibM**.

VML

- При большом количестве итераций цикла может иметь смысл предварительно вычислить значения математических функций сразу для всех итераций цикла (если их аргументы известны заранее).
- Для такого случая идеально подходит библиотека **VML** (vector math library), являющаяся частью Intel MKL (math kernel library).

Использование VML

```
void exp_loop_vml(float* a, float* b, float* c,
                  float* d, int n)
{
    vsExp(n, d, d);
    #pragma ivdep
    for (int i = 0; i < n; i++)
        a[i] = b[i] + c[i] + d[i];
}
```

Сравнение версий с VML и SVML

- Оба варианта векторизуют и вычисление экспоненты, и цикл со сложением, поэтому являются достаточно эффективными и существенно превосходят невекторизованную версию.
- То, какая из них является более эффективной, зависит от количества итераций цикла **n**.
- В таких случаях наблюдается следующее поведение:
  - при малом количестве итераций цикла порядка десятков или сотен, предпочтительна версия с использованием SVML,
  - при значительном количестве итераций цикла предпочтительна версия с использованием VML.

Более сложные примеры векторизации

Задача

- При вычислении справедливой цены опциона Европейского типа в популярной двухфакторной модели HJM возникает код следующего вида:

```
double* arr = (double*)
      malloc(size*sizeof(double));
arr[0] = 1.1;
for (i = 0; i < size - 1; i++)
{
    double c0 = sigma1*pow(arr[i], alpha);
    double c1 = sigma2*pow(arr[i], beta);
    arr[i+1] = (c0*z1[i] + c1*z2[i]) + 1;
}
```

Анализ возможностей векторизации

- Очевидно, все элементы массива **arr** зависимы между собой и векторизация цикла for невозможна.
- Однако в данном случае возможна векторизация вычисления **pow** внутри цикла.
- Так как компилятор применяет автоматическую векторизацию лишь для циклов, необходимо трансформировать две скалярные операции в цикл из двух итераций.
- Кроме того, необходимо использовать **#pragma vector always**, в противном случае цикл, вероятно, не будет векторизован, так как компилятор сочтет его слишком коротким.

Векторизация операций pow

```
double* arr = (double*)
      malloc(size*sizeof(double));
arr[0] = 1.1;
for (i = 0; i < size - 1; i++)
{
    double c[2], sigma[2] = {sigma1, sigma2};
    double power[2] = {alpha, beta};
    #pragma vector always
    for (int k=0; k < 2; k++)
        c[k] = sigma[k] * pow(arr[i], power[k]);
    arr[i+1] = (c0*z1[i] + c1*z2[i]) + 1;
}
```

Векторизация и if

- В той же задаче далее необходимо произвести суммирование по всем путям Монте-Карло, для которых выгода положительна, и возникает код следующего вида:

```
for (int i = 0; i < size; i++)
{
    double s = coeff * exp(arr[i]);
    double payoff = s - K;
    if (payoff > 0.0)
        sum = sum + payoff;
}
```

Векторизация и if

- Хотя условные операции в целом нежелательны для векторизации, при простой структуре условия они не являются помехой.
- Данный цикл векторизуется с использованием векторного сравнения нескольких пар чисел с плавающей запятой.
- Другим возможным вариантом написания цикла была бы замена условия на явное взятие максимума:

```
for (int i = 0; i < size; i++) {
    double s = coeff * exp(arr[i]);
    double payoff = s - K;
    sum = sum + std::max(payoff, 0.0);
}
```

Использование VML

- При большой длине цикла **size** (в данной задаче это количество путей Монте-Карло и, поэтому, является весьма большим) также имеет смысл вычислять значение экспоненты для всех аргументов с использованием VML.
- При этом код приобретает вид (в предположении, что содержимое массива **arr** после завершения цикла не используется):

```
vdExp(n, arr, arr);
for (int i = 0; i < size; i++)
    sum = sum + std::max(coeff * arr[i] - K, 0.0);
```

Подробнее про #pragma simd и Array Notation

Использование директивы SIMD…

```
void add_floats(float *a, float *b, float *c, float *d,
float *e, int n){
    int i;

    #pragma simd
    for (i=0; i<n; i++){
        a[i] = a[i] + b[i] + c[i] + d[i] + e[i];
    }
}
```

Использование директивы SIMD…

- ***vectorlength(n)*** – данный параметр определяет количество итераций цикла, которые могут быть выполнены независимо за одну векторную операцию

```
#pragma simd vectorlength(4)
for (i = 0; i < n; i++) {
    a[i] = a[i] + b[i] + c[i];
}
```

- ***linear(var1:step1 [,var2:step2]...)*** – этот параметр сообщает компилятору, что переменные *var* инкрементируются с шагом *step* на каждой итерации цикла

```
#pragma simd linear(k:j)
for (i = 0; i < n; i += step) {
    k += j;
    a[i] = a[i] + b[n - k + 1];
}
```

Использование директивы SIMD…

- ***reduction(oper:var1 [,var2]…)*** – параметр аналогичен соответствующему параметру директивы OMP, обеспечивает выполнение операции редукции для заданного списка переменных по окончании выполнения операций цикла

```
int x = 0;
#pragma simd reduction(+:x)
for (i = 0; i < n; ++i)
    x = x + A[i];
```

- ***private(var1[, var2]...)*** – параметр аналогичен соответствующему параметру директивы OMP, сообщает компилятору о необходимости создания отдельного экземпляра переменной для каждой итерации цикла. Определены также параметры ***firstprivate*** и ***lastprivate***, позволяющие задать начальное и конечное значение переменной в рамках каждой итерации цикла

Использование директивы SIMD

```
double pi(int count)
{
    int i;
    double pi = 0.0;
    double t;
    #pragma simd private(t) reduction(+:pi)
    for (i=0; i<count; i++) {
        t = (double)((i+0.5)/count);
        pi += 4.0/(1.0+t*t);
    }
    pi /= count;
    return pi;
}
```

Технология Array Notation…

- С помощью выражения ***A[:]*** задается весь массив A (размер массива определяется на этапе компиляции, а значит должен быть константным)
- Выражение ***A[start_index : length]*** задает отрезок массива, начиная со *start_index* длиной *length*

```
float b[10];
..
  = b[2:6];
// section operands can be variables also
..
```

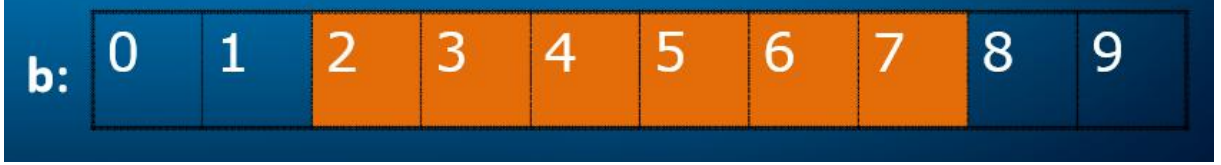

Технология Array Notation…

- Выражение ***A[start_index : length : stride]*** говорит о том, что мы хотим использовать каждый *stride* элемент массива, начиная со *start_index*. Количество таких элементов должно быть равно *length*

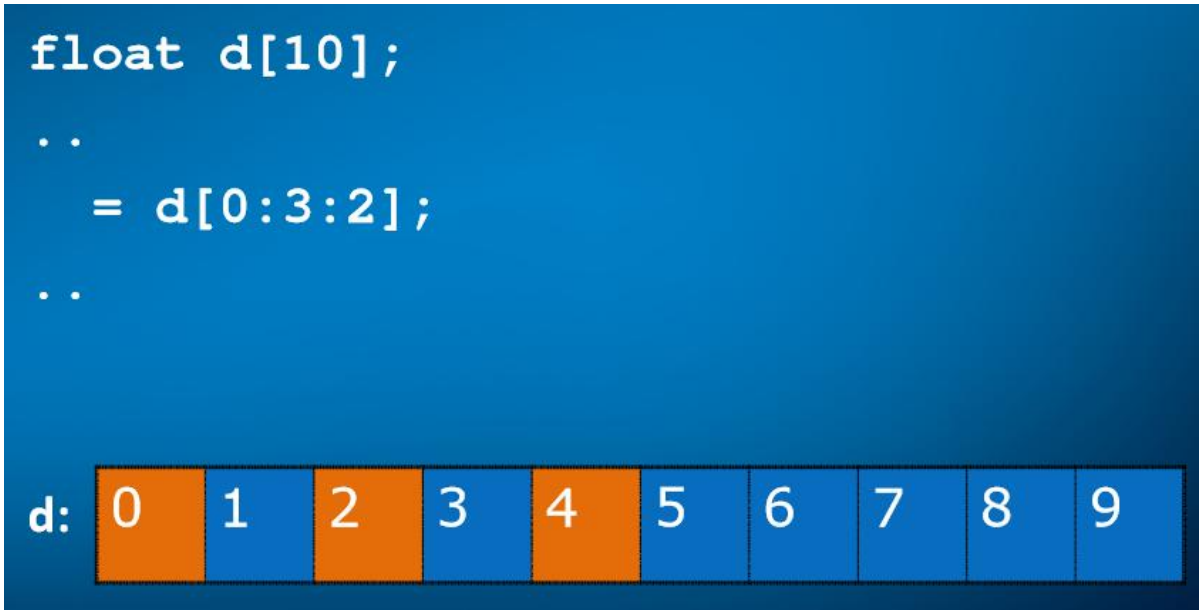

- Поддерживаются многомерные массивы

Технология Array Notation: поддерживаемые операции…

- Возможно использование операторов языков C/C++:

```
d[:] = a[:] + (b[:]*c[:]);
```

- Возможна передача массивов в качестве аргументов функции. При этом вызов функции осуществляется для каждого заданного элемента массива:

```
b[:] = func(a[:]);
```

- Поддерживается операция редукции для сложения, минимума, максимума и т.п.:

```
sum = __sec_reduce_add(a[:]);
```

Технология Array Notation: поддерживаемые операции…

- Поддерживаются условные операторы if-then-else:

```
if (mask[:])
{
    a[:] = b[:];
}
```

- Поддерживаются операции типа scatter/gather, с помощью которых можно собрать определенные элементы одного массива в другой (собрать разрозненные элементы в один непрерывный массив), и наоборот:

```
c[:] = a[b[:]]; //gather
a[b[:]] = c[:]; //scatter
```

Технология Array Notation: поддерживаемые операции

- Поддерживаются операции сдвига. Операция ***shift*** сдвигает элементы массива на *shift_val* позиций влево/вправо, освободившиеся элементы заполняются значением *fill_val*. Операция ***rotate*** обеспечивает циклический сдвиг элементов влево/вправо на ***rotate_val*** позиций. Результат работы этих функций записывается в новый массив:

```
b[:] = __sec_shift_right(a[:], shift_val, fill_val);
b[:] = __sec_shift_left(a[:], shift_val, fill_val);
b[:] = __sec_rotate_right(a[:], rotate_val);
b[:] = __sec_rotate_left(a[:], rotate_val);
```

Технология Array Notation: принципы работы

- Размер массива должен быть известен на стадии компиляции. Если используется динамический массив, то при использовании данной нотации необходимо явно указывать начальную позицию (*start_index*) и длину (*length*) отрезка массива.
- В случае если векторизация кода невозможна, будет сгенерирован обычный цикл.
- Оптимальный векторный код будет получен только в случае работы с выровненными данными.
- Требуется соответствие рангов и длин массивов в рамках одной операции.

Технология Array Notation: скалярное произведение

- Скалярный код:

```
float dot_product(unsigned int size, float *A, float *B)
{
    int i;
    float dp=0.0f;
    for (i=0; i<size; i++)
    {
        dp += A[i] * B[i];
    }

    return dp;
}
```

- Векторный код:

```
float dot_product(unsigned int size, float A[size], float
B[size])
{
    return __sec_reduce_add(A[:] * B[:]);
}
```

Дополнительные задания и литература

Задания для самостоятельной работы

- Для рассматриваемого в разделе 2 примера сравните время работы исходной (скалярной) и векторизованной версий на центральном процессоре и сопроцессоре Intel Xeon Phi. Сравните время работы версий с использованием различных средств векторизации. Объясните полученный результат.
- Реализуйте умножение матрицы на вектор. Воспользуйтесь отчетом о векторизации и проверьте, происходит ли векторизация вашей реализации? При необходимости внесите изменения для обеспечения векторизации. Зависит ли векторизация от того, как хранится матрица: по строкам или по столбцам?

Задания для самостоятельной работы

- Проведите исследование, аналогичное предыдущему заданию, для операции вычисления матричного произведения по определению.
- Рассмотрите пример из раздела 5. Экспериментально определите минимальное количество итераций цикла, при котором предварительное вычисление всех экспонент с использованием VML становится более эффективным по сравнению с использованием SVML.

Литература

1. Rahman R. Intel® Xeon Phi™ Coprocessor Vector Microarchitecture. URL: [http://software.intel.com/en-us/articles/intel-xeon-phi-coprocessor-vector-microarchitecture]
2. Green R. Vectorization Essentials. URL: [http://software.intel.com/en-us/articles/vectorization-essential]
3. Jeffers J., Reinders J. Intel Xeon Phi Coprocessor High Performance Programming // Morgan Kaufmann, 2013.

Авторский коллектив

- Бастраков Сергей Иванович,

  ассистент кафедры
  Математического обеспечения ЭВМ факультета ВМК ННГУ

  bastrakov@vmk.unn.ru
- Сиднев Алексей Александрович,

  ассистент кафедры
  Математического обеспечения ЭВМ факультета ВМК ННГУ

  sidnev@vmk.unn.ru