



**Нижегородский государственный университет
им. Н.И.Лобачевского**

Факультет Вычислительной математики и кибернетики

Программирование для Intel Xeon Phi

**Лекция №4
Векторные расширения Intel Xeon Phi**

При поддержке компании Intel

Мееров И.Б.

Кафедра математического обеспечения ЭВМ

Содержание

- ❑ Введение
- ❑ Векторные расширения. Краткий обзор
 - Типы данных и регистровый пул
 - Обзор основных типов операций
 - Расширенная поддержка математических функций
- ❑ Векторизация в программах на языке высокого уровня
- ❑ Векторизация и математические функции
- ❑ Заключение
- ❑ Литература



Введение



Введение...

- ❑ Начиная с середины XX века, программирование проделало большой путь и постоянно продолжает развиваться
 - программирование в машинных кодах,
 - программирование на ассемблере,
 - программирование на языках высокого уровня.
- ❑ Оптимизирующие компиляторы (Intel C/C++ Comiler, Intel Fortran Compiler и др.) умеют
 - *использовать новые наборы команд;*
 - генерировать код, **ориентированный на современные центральные процессоры.**



Что это значит?

Введение

- ❑ Парадигма **SIMD** – single instruction multiple data
- ❑ MMX, SSE, SSE2, SSE3..., SSE4, AVX, векторные расширения Intel Xeon Phi

1.25	2.25	2.0	1.0
+			
2.0	1.15	1.25	2.0
=			
3.25	3.4	3.25	3.0

- ❑ Специальные регистры, специальные векторные инструкции (арифметика, работа с памятью...).

Как этим воспользоваться?



Векторные расширения. Краткий обзор



Введение

- ❑ Векторные расширения присутствуют в наборах команд процессоров различных производителей и архитектур.
 - Intel: MMX – SSE – SSE2 – SSE3 – SSE4 – AVX – расширения в XeonPhi.
 - AMD: 3DNow!
 - ARM: NEON (во встраиваемых системах)
- ❑ Рассмотрим кратко векторные расширения, реализованные в Intel Xeon Phi, чтобы составить общее впечатление о сути вопроса для лучшего понимания того, как соотносится расчетный код на C/C++ и машинный/ассемблерный коды, порождаемые компилятором.



Типы данных и регистровый пул

- ❑ В каждом ядре Xeon Phi сконструирован специальный модуль векторной обработки (VPU, vector processor unit)
 - 32 512-разрядных zmm-регистра; двукратное увеличение размера по сравнению с AVX
 - векторный FMA, fused multiply–add: $a = a + b * c$ с однократным округлением.
- ❑ Одновременные действия над 16 32-битными целыми числами или 8 64-битными целыми числами или 16 числами с плавающей запятой одинарной точности или 8 числами с плавающей запятой двойной точности. Поддерживаются операции с комплексными данными.
- ❑ Большинство операций – тернарные (2 аргумента и один результат). По некоторым данным это приводит к 20% приросту производительности.



Обзор основных типов операций

- ❑ **Арифметические операции:** сложение, вычитание, умножение, деление, FMA (для вычислений с плавающей запятой).
- ❑ **Операции преобразования типов,** позволяющие выполнять повышающие и понижающие преобразования согласно определенным правилам (см. [1, 3]).
- ❑ **Логические операции,** позволяющие выполнять векторные сравнения, находить минимум и максимум и т.д.
- ❑ **Операции доступа к данным** (загрузка/выгрузка память/регистр; scatter/gather, предвыборка, streaming stores). Могут применяться *маскирование, swizzle, shuffle*.



Расширенная поддержка математических функций

- В рамках Intel Xeon Phi была реализована расширенная поддержка некоторых математических функций:

Команды для вычисления в одинарной точности:

Функция	Латентность	Пропускная способность
$1/x$	4	1
$1/\text{sqrt}(x)$	4	1
$\log_2(x)$	4	1
2^x	8	2

- **$\text{sqrt}(x)$, a^x и деление** могут быть вычислены при помощи указанных функций.



Векторизация в программах на языке высокого уровня



Введение

- ❑ Вычислительные ядра Intel Xeon Phi могут выполнять однотипные вычисления,
 - оперируя векторами из целых чисел или чисел с плавающей запятой,
 - обладают широким спектром
 - математических операций,
 - логических операций,
 - операций с битами,
 - операций работы с памятью.

- ❑ **Как написать программу, чтобы задействовать эти возможности?**



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.

Больше контроль.
Сложнее в реализации



Векторизация. Используем векторизованные библиотеки

❑ **MKL** и не только.

❑ **Проблемы:**

- Не все, что нам нужно, есть в библиотеке.
- Реализация, присутствующая в библиотеке, не всегда оптимальна для нашей конкретной задачи.
- Сложности интеграции, поддержки, миграции на другие платформы.



Векторизация. Используем C/C++ или Fortran в сочетании с оптимизирующим компилятором

Intel Compilers (предпочтительно), **gcc**

- ❑ Крайне желательно минимизировать всевозможные зависимости по данным.
- ❑ Нежелательно вызывать функции в вычислительно трудоемких циклах. Однако вызов функции тоже не приговор. Компилятор может встроить код функции и успешно векторизовать цикл.
- ❑ Необходимо следить за выравниванием данных в памяти, то есть за их размещением с «правильных» адресов, кратным определенному числу байт (размеру кеш-линии, размеру векторного регистра).

SSE: по 16, AVX: по 32, Xeon Phi: по 64

`__declspec(aligned), __mm_malloc()...`



Векторизация. Используем C/C++ или Fortran в сочетании с оптимизирующим компилятором

- ❑ Необходимо стараться обеспечить однородный доступ к памяти, когда мы загружаем/выгружаем данные, лежащие последовательно (крайне желательно) либо с одинаковым шагом (допустимо).
- ❑ Необходимо сводить к минимуму смешивание объектов разных типов данных в выражениях.
- ❑ Необходимо по возможности избавляться от условных операторов в теле внутреннего цикла. Раньше компилятор в принципе отказывался векторизовывать такие циклы. Сейчас в ряде случаев ему удастся это сделать.

Примеры:



Векторизация. Используем C/C++ или Fortran в сочетании с оптимизирующим компилятором

Пример 1:

```
#pragma simd
```

```
#pragma vector aligned
```

```
for (int i = 0; i < n; i++) { s = s + max(a[i],0); }
```

Пример 2:

```
#pragma simd
```

```
#pragma vector aligned
```

```
for (int i = 0; i < n; i++)
```

```
    if (a[i] == key) {
```

```
        Index = i; break;
```

```
    }
```



Векторизация. Используем C/C++ или Fortran в сочетании с оптимизирующим компилятором

- ❑ по возможности не использовать объектно-ориентированные конструкции в расчетах; существуют способы умелого сочетания высокоуровневой объектно-ориентированной архитектуры и низкоуровневого программирования вычислительно трудоемких участков кода;
- ❑ стремиться к достаточно существенному объему работы во внутренних циклах; заметим, что компилятор преимущественно векторизует именно внутренние циклы, поэтому необходим простор для его деятельности.



Векторизация. Используем C/C++ или Fortran в сочетании с оптимизирующим компилятором

Пример кода, автоматически векторизуемого компилятором:

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

- ❑ **restrict**: мы говорим компилятору, что доступ в указанную память будет осуществляться только через указатель, использованный при объявлении. Не забываем ключ **–restrict**.
- ❑ Это необходимо, что компилятор зафиксировал факт отсутствия зависимостей по данным между массивами a, b и c и успешно векторизовал цикл.



Векторизация. Используем ключи и директивы компилятора

- ❑ -O2, -O3
- ❑ #pragma ivdep
- ❑ #pragma vector
 - always
 - aligned
 - nontemporal
- ❑ #pragma simd (с параметрами)
 - самый мощный на сегодняшний день инструмент;
 - необходимо пользоваться с осторожностью.



Векторизация. Используем ключи и директивы компилятора

#pragma ivdep

#pragma vector always

#pragma vector aligned

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

Или так:

#pragma simd

#pragma vector aligned

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



Векторизация. Array Notation и Elemental Function в рамках технологии Intel Cilk Plus

- ❑ Технология Intel Cilk Plus позволяет разрабатывать эффективные параллельные программы для систем с общей памятью, по сравнению с OpenMP
 - упрощая обучение начинающих параллельному программированию,
 - предоставляя мощные, логичные и достаточно простые средства организации параллелизма с использованием механизма логических задач.
- ❑ Наряду с этим, в Cilk Plus добавлена так называемая Array Notation, что позволяет записывать вычисления в циклах как бы без самих циклов, явно показывая компилятору, что эти вычисления можно «положить» на векторную архитектуру.



Векторизация. Array Notation и Elemental Function в рамках технологии Intel Cilk Plus

```
void test(float * restrict a, float * restrict b,  
          float * restrict c, int n)  
{  
    c[0:n] = a[0:n] * b[0:n] + a[0:n];  
}
```

- ❑ Кроме того, в Intel Cilk Plus вводится специальный вид функций, **Elemental Function**. Эти функции, описанные специальным образом, могут выполнять операции над единицей данных. Такие функции могут быть использованы для векторизации и распараллеливания циклов.
- ❑ Подробнее Array Notation и Elemental Functions рассматриваются в лекции 5.



Векторизация. Интринсики и ассемблер

- ❑ **Большой контроль:** делаем ровно то, что хотим.
- ❑ **Сложность разработки:** нужно хорошо знать систему команд и особенности архитектуры, а также иметь опыт низкоуровневого программирования.
- ❑ **Трудности с переносимостью кода** на другие программно-аппаратные платформы.

Изучение выходит за рамки данного курса.



Векторизация и математические функции



Введение

- ❑ Отдельно необходимо обсудить важный вопрос о сочетании векторизации и математических функций, вызываемых в циклах, так как именно на вычисление этих функций приходится основное время работы значительного числа прикладных программ.
- ❑ Ранее мы установили факт наличия в наборе команд Intel Xeon Phi специальных инструкций для вычисления четырех математических функций.

Как быть с остальными функциями?



Пример

```
void test(float * a, float * b,  
          float * c, int n)  
{  
    #pragma simd  
    #pragma vector aligned  
    for (int i = 0; i < n; i++)  
        c[i] = a[i] * b[i] + sinf(a[i]);  
}
```

Отчет: цикл векторизован.

Вопрос: как векторизуется синус?



Реализации математических функций

- ❑ **LibM** – модуль компилятора.

ICC содержит быстрый LibM, оптимизированный под современные архитектуры.

- ❑ **SVML** (short vector math library) – модуль компилятора ICC.

Используется, если цикл векторизован.

Мат. функции реализованы с использованием SIMD, вычисляются для короткого вектора аргументов. Длина вектора соответствует длине xmm, ymm, zmm регистра.

- ❑ **VML** (vector math library) – часть библиотеки MKL.

Используется при явном вызове функций (vsSin, vdSin...).
Вычисляет значение функции в N точках.



Реализации математических функций

- ❑ **LibM** (см. math.h). Перекомпиляция ICC в программах, активно использующих мат. функции, часто приводит к ускорению расчетов.

- ❑ **SVML vs. VML**

VML может выигрывать у SVML на больших длинах, но не всегда (эффект существенно зависит от архитектуры).

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

Не векторизован: **LibM**

Векторизован: **SVML**

VML: vsSin(n, a, c);



Реализации математических функций. Точность

Настройки, влияющие на точность (ICC):

- ❑ -fp-model
- ❑ -fimf-domain-exclusion
- ❑ -fimf-precision

Настройки, влияющие на точность (MKL/VML):

- ❑ Режимы High Accuracy (HA), Low Accuracy (LA), Enhanced Performance (EP).
- ❑ Могут быть настроены для конкретного вызова.



Авторский коллектив

- Мееров Иосиф Борисович,
к.т.н., доцент, зам. зав. кафедры
Математического обеспечения ЭВМ факультета ВМК ННГУ
meerov@vmk.unn.ru

