



Оптимизирующий Компилятор на базе UTL и LLVM для ARM и MIPS

*Александр Юльевич Дроздов
Виктор Евгеньевич Владиславлев
Святослав Владимирович Кузьмич*

Открытая Конференция по Компиляторным Технологиям

Декабрь 2015, Москва



- Предпосылки
- Универсальная Библиотека Трансляции (UTL)
- Трансформации
 - Оптимизации доступа в память
 - Авто-Распараллеливание
 - Векторизация
- Производительность
 - Smart Compiler (SMCC)
 - Замеры на ARM
 - Замеры на MIPS

Предпосылки



ARM для серверов

- **Qualcomm** анонсировала **24-ядерный ARM** для серверов
- **Cavium, Broadcom, Applied Micro, AMD** и проч. сделали это ранее
- **Baidu**: x86 -> ARM уменьшила общие издержки на **25%**
- **Rikor** создала системы хранения данных на основе ARM серверов
- **Linaro**: сообщество с девизом «open source software for ARM SoCs»




Dell



HP

Возрождение MIPS

- **Imagination™** заявлял: MIPS займет до 30% от рынка ARM
- Ядра **Warrior**— “new architecture and best-in-class performance”
- **Baikal Electronics** – первый разработчик процессоров на основе Warrior P5600



Made in Russia

Development Tools, Compiler firstly

- Для x86 есть выдающиеся компиляторы от Intel or Sun
- Для ARM сообщество докручивает GNU решение – linaro-gcc
- MIPS – довольствуется базовым портом GCC и LLVM




Baikal-T1

Универсальная Библиотека Трансляции






- Большой опыт в области оптимизирующей компиляции (Sun, Elbrus, Intel, GNU, LLVM) воплотился в *Компонентная Технология Оптимизирующей Трансляции (КТОТ)* – подход, который абстрагирует алгоритмы анализа и оптимизаций от конкретного промежуточного представления
- УБТ (или UTL) – реализация КТОТ – была апробирована:
 - в составе GNU и LLVM цепочек трансляции
 - для архитектур x86, ARM, MIPS, Itanium, Power, и Cell B.E
 - в двоичном трансляторе QEMU – x86->ARM
 - в проприетарном JIT-компиляторе SMI
- UTL
 - Может применяться в разных пользовательских цепочках трансляции
 - Имеет весь основной инструментарий компиляторостроения
 - Содержит Алгоритмы анализа и Оптимизаций
 - На его основе реализованы Авто-распараллеливатель и Векторизатор




Глобальные Трансформации Данных **struct**



- Направлены на повышение *локальности* данных
- Требуют режима «вся программа» (whole program mode)
- Необходим сложный анализ – Data Structure Analysis (в LLVM до 2.8)
- На **429.mcf**, **462.libquantum** и **179.art** дает 50-70%



429.mcf




462.libquantum
179.art

Глобальные Трансформации Данных **array**



- Линеаризация доступа – убираем промежуточные LOADs
- Необходим контроль нового – линеаризованного – индекса на переполнение
- Требуется whole program mode
- Классика: на **183.quake** дает 100%



- Анализ многоуровневой аллокации

полезен в **464.h264ref**

- Доказывает независимость STOREs, что дает возможность распараллелить цикл


```
static int *****BlockSAD;
BlockSAD = malloc();
BlockSAD[i] = malloc();
BlockSAD[i][j] = malloc();
BlockSAD[i][j][k] = malloc();
BlockSAD[i][j][k][l] = malloc();...
for(pos=0;pos<max_pos;pos++) { ...
    for(blky=0;blky<4;blky++) { ...
        BlockSAD[list][ref][7](ind++)[pos]+= ...
        BlockSAD[list][ref][7](ind++)[pos]+= ...
    }
}
```

Предподкачка




- Направлена на уменьшение промахов в кэш
- Требуется аппаратной поддержки – спец. инструкций
- Результат сильно зависит от архитектуры и ее подсистемы памяти
- Не требует глобального контекста
- На **470.lbm**:
 - **Cortex-A15** Chromebook – **30%**
 - **Aarch64** – **18%**
 - **MIPS** – несколько процентов

```
for(;;i+=20) {  
    = srcGrid[i];...  
    = srcGrid[i+19];  
    ...  
}  
// sizeof(srcGrid[0]) is 8
```



```
for(;;i+=20) {  
    prefetch( srcGrid[i+20]);  
    prefetch( srcGrid[i+28]);  
    prefetch( srcGrid[i+23]);  
    = srcGrid[i];... = srcGrid[i+19];  
}
```




Cacheline size – 64 bytes

Авто-распараллеливание



- Параллелизм – секционный и **циклический**
- Чтобы распараллелить цикл достаточно отсутствие *кросс-итерационных* зависимостей
- Редукции – возможны; но надо помнить о **fast-math** (**183, 435, 465**)
- Swar-рекуррентности (**183, 470**) – позволяют распараллелить внутренний цикл
- Зависимости по памяти (массивы)
 - Никогда не зависят – нет проблем
 - Всегда – аналогично скалярам
 - Неизвестно – динамическая проверка
- Расширяем на массивы понятия *Private, First-, Last- Private, Reduction* переменных
- Используем системы диофантовых уравнения и неравенств
- Настройка эвристик; например, inline (**168.wupwise**) – много вызовов больших функций ~1850 инструкций; пропация констант, клонирование, получаем 260 и 305
- Предварительные трансформации; code replication (**464.h264ref**) – из цикла получается 3, 2 из которых распараллеливаются







Private, First-, Last- private, Reduction



Распространим определения со скаляров на агрегатные объекты

- **Private массив:** на каждой итерации LOAD читает из массива только то, что было записано на этой же итерации
- **First-private:** LOAD читает только либо то, что было записано на этой же итерации, либо то, что записано в массив до цикла
- **Last private:** private или first-private массив в чтении после цикла ТОЛЬКО того, что записано на последней итерации (*сильное – достаточное – условие*)
- **Reduction:** Аналогично скалярному случаю



Определение приватности



Пробуем доказать, что массив `double a[]` является private

Ставим решателю задачу в виде системы Диофантовых уравнений и неравенств

В качестве решателя **можно** использовать библиотеку Microsoft **z3**

```
for (i=0; i<n; i++) {  
    if (P(i))  
        for (j=j1; j<j2; j++)  
            a[j]=... ;  
        for (k=k1; k<k2; k++)  
            if (Q(k))  
                ...=a[k];  
}
```

$$\forall i \forall k: k_1 \leq k \leq k_2, Q(k), 0 \leq i < n$$
$$\exists j: a + 8j = a + 8k, j_1 \leq j < j_2, P(i), 0 \leq i < n$$

Аллокация Копий Массивов



Для создания копии массивов надо знать их размер

1. В идеале – **найти диапазон адресов**, используемых в цикле (учесть предикаты, например, над циклом)
2. Использовать **информацию о размере** при аллокации исходного массива; возможно для массивов
 - а. выделенных в той же процедуре, что и цикл, или
 - б. глобальных.

размер массива может быть больше используемой части, что **увеличивает накладные расходы на инициализацию и восстановление**

для private-массивов достаточно оценки сверху
для first- last- private и reduction – точный размер

3. Аллокация небольшого **массива с реаллокацией** и копированием при необходимости

Небольшие накладные расходы; невозможно точно оценить затраты на перестроение

4. Вставка предварительного цикла определения диапазона используемых адресов

существенные накладные расходы; точный размер до выделения копии массива

```
for (i=Lo; i<Hi; i++)  
    a[5*i-7]
```

```
p = malloc(100500);  
...  
for (;;) {  
    p[]
```


```
arCpy = malloc(sz);  
...  
if (ind>sz) {  
    sz+=1050;  
    realloc(arCpy, sz);  
    // copy, if needed
```

```
for (;;) {  
    sz=max(sz, ind);  
    malloc(sz);
```


Векторизация




- Мелкозернистый параллелизм
- Основан на использовании SIMD-инструкций
- Рассматривается только цикловая векторизация
- Классическая схема: или векторизуются все инструкции цикла, или никакие
- Частичная векторизация: векторизуется часть инструкций цикла
- Подход UTL – комбинированная схема:
 - создается копия раскрученного цикла
 - к которой применяется частичная векторизация
 - оригинал держится не векторизованным
 - перед циклами вставляется динамическая проверка для выбора версии цикла




Исходный цикл



«unroll» с фактором f



Копируем и частично векторизуем




Вставляем проверку

Векторизация 456.hmmmer



Показан граф зависимости
исходного цикла

- черные стрелки – зависимость по регистрам
- красные – по памяти
- число рамок – ранг вектора
- желтый – инварианты
- фиолетовый – выход
- зеленый – узлы упаковки
- розовый – узлы распаковки
- аквамарин – память
- x86: **87.3%**
- ARM: **16%**
- MIPS: **почти ничего**




Векторизация 435.gromacs



x86: 85.8%

ARM: 26%

MIPS: ничего



SMCC – Smart Compiler



- Мы интегрировали UTL с цепочкой LLVM – компилятор Clang
- Для FORTRAN – пришлось поддерживать
- **Benchmarks:** SPEC/CPU2006 test suit was run
- **Platforms:**

ARM

APM X-Gene XC-1 Mustang board Aarch64 **Octa** 1.6GHz, 8Gb RAM

MIPS


Creator CI20 SoC: Ingenic JZ4780 CPU: **Dual** 1.2GHz XBurst MIPS32 little endian 32kl + 32kD per core 512K shared L2, 1Gbyte DDR3

- **Compilers for comparison:**
 - Linaro-GCC: 4.9 (for ARM) and GCC 4.9.2 (for MIPS)
 - Clang: clang-3.7 + dragonegg (*for FORTRAN bmks*)
- **Compiler options:** (*common for all compilers*)
`-flto -O3 -mcpu=cortex-a57`
- **Environment:** `OMP_PROC_BIND=true` is set to minimize migrations from core to core

Производительность на ARM 8-core




- SPEC/CPU2006, reference data
- Smcc wins **47%** and **55%** Linaro-gcc and LLVM correspondingly (in geomean)



Производительность на MIPS 2-core



- SPEC/CPU2006 excluding 434.zeusmp, train data considered
- Smcc wins **13%** and **20%** GCC and LLVM



Производительность на ОДНОМ Ядре



- Авто-распараллеливание – основной драйвер прироста производительности: **50-550%** на 8-core ARM
- Но даже на одном ядре SMCC выигрывает у GCC и LLVM
 - **3%** и **5%** на ARM
 - **2.5%** и **6%** на MIPS соответственно
- На задаче **410.bwaves** на MIPS GCC и LLVM проигрывают **30%** и **44%**
- **pow(x, 1.75)** не был заменен на **SQRT** и **MUL** инструкции:

$$x^{1,75} = x \cdot \sqrt{x} \cdot \sqrt{\sqrt{x}};$$

- И GCC, и LLVM делают это для других архитектур

*Создавать архитектуру без эффективных средств разработки
может свести к нулю все усилия разработчиков железа*