

Производительность расчетов в OpenFOAM с использованием GPU

Александр Монаков

amonakov@ispras.ru

Институт Системного Программирования

5 декабря 2014 г.

Гетерогенные системы

- Наращивание вычислительной мощности суперкомпьютеров: увеличение количества узлов/процессоров
- Повышение производительности процессоров затруднено:
 - Ограничения по тепловыделению
 - Приоритет на производительности однопоточного кода

Возможное решение: гибридная архитектура

- Дополнить центральный процессор акселератором
- Архитектура акселератора оптимизируется под массивно-параллельные задачи
- GPU: NVIDIA Tesla, AMD FirePro
- Intel MIC

GPU

- Специализированная массивно-параллельная архитектура
- 1-4 TFLOPS, 100-300 GB/s на одном устройстве
- Требуют задач с высоким параллелизмом

Преимущества

- 1 Производительность
- 2 Энергоэффективность (10x производительность при 2x энергопотреблении)
- 3 Доступность
 - В Top500: 62 системы с акселераторами, 44 NVIDIA
 - В персональных компьютерах

Использование в OpenFOAM

50-80% времени счета: решение СЛАУ

- PCG: Метод сопряженных градиентов
- AMG: Многосеточный метод

Рассматриваем PCG

- Производительность ограничена:
 - Пропускной способностью памяти
 - Скоростью сети
- Сложности при переносе на GPU
 - Предобуславливание
 - Поддержка MPI
 - Минимизация накладных расходов

Предобуславливание на GPU

OpenFOAM: обычно используется DILU

- Подготовка/применение: решение треугольных систем
- Эффективный, но не обладает высоким параллелизмом
- Переупорядочивание может повысить параллелизм за счет снижения эффективности

Диагональное преобуславливание:

- Подготовка/применение: деление на диагональные коэффициенты
- Высокий параллелизм, низкая эффективность

Предобусловливание на GPU

Наш выбор для GPU: AINV

$$W^T A Z = D + e$$

- Подготовка: вычисление явного разложения приближенной обратной матрицы
- Применение: домножение на две разреженные матрицы
- Хорошо подходит для GPU
- Затраты на подготовку соизмеримы с решением СЛАУ

Асинхронное вычисление AINV

Предположим:

- ① Что связность сетки не меняется
⇒ Портрет разреженной матрицы СЛАУ фиксирован
- ② СЛАУ для последних шагов по времени имеют близкие коэффициенты
⇒ Можно переиспользовать предобуславливатели

Тогда:

- ① Предобуславливатели вычисляются асинхронно в отдельном потоке
- ② На GPU используется последний посчитанный предобуславливатерь

Поддержка MPI

Схема параллельного счета в OpenFOAM:

- Разделение сетки (без перекрытия или “гало”)
- Межпроцессорные границы – частный случай граничных условий на сетке
- Процессоры обмениваются коэффициентами при доможножении на матрицу системы
- Предобуславливание выполняется без MPI-коммуникаций

Поддержка на GPU:

- Сводится к поддержке произвольных граничных условий
- Параллельно с домножением на матрицу на GPU:
 - 1 Скопировать граничные коэф-ты в память CPU
 - 2 Вызвать методы обновления граничных условий
 - 3 Просуммировать обновленные коэф-ты на GPU

Снижение накладных расходов

- ① Преобразование матрицы в GPU-формат только на первом шаге

На последующих шагах – обновлять ненулевые коэффициенты

- ② Автоматическая настройка

- Оптимизация умножения разреженных матриц на GPU
- Разреженность предобуславливателя AINV

- ③ Минимизация CPU-GPU коммуникаций

- Исключение лишних копирований
- CUDA-aware MPI
- Конвейеризованные варианты метода сопряженных градиентов

Конвейеризованные методы сопряженных градиентов

$$s = M^{-1}r$$

$$\delta = (s, r)$$

$$\beta = \delta_i / \delta_{i-1}$$

$$p = s + \beta p$$

$$s = Ap$$

$$\gamma = (s, p)$$

$$\alpha = \delta_i / \gamma$$

$$x = x + \alpha p$$

$$r = r - \alpha s$$

$$m = M^{-1}w$$

$$n = Am$$

$$\beta = \gamma_i / \gamma_{i-1}$$

$$\alpha = \gamma_i / (\delta - \beta \gamma_i / \alpha)$$

$$z = n + \beta z$$

$$q = m + \beta q$$

$$s = w + \beta s$$

$$p = u + \beta p$$

$$x = x + \alpha p$$

$$r = r - \alpha s$$

$$u = u - \alpha q$$

$$w = w - \alpha z$$

$$\gamma_i = (r, u)$$

$$\delta = (w, u)$$

Зависимость производительности от размера сетки

Модельная задача: `icoFoam`, `cavity3d`; 12 ядер, 2 GTX Titan

- 373K: 16 с на CPU, 18 с на GPU
- 1M: 91 с на CPU, 60 с на GPU (общее время)
73 с на CPU, 43 с на GPU (ускоренная часть)
- 2M: 239 с на CPU, 113 с на GPU (общее время)
199 с на CPU, 71 с на GPU (ускоренная часть)
- 8M: 2160 с на CPU, 563 с на GPU (общее время)
1824 с на CPU, 300 с на GPU (ускоренная часть)

Текущие работы

- Включение в релиз-версии FOAM-Extend
текущая версия доступна на Github:
<https://github.com/amonakov/ispm-sparse-lib>
<https://github.com/amonakov/openfoam-extend-foam-extend-3.1>
- Итерационные методы для асимметричных систем
- Решение блочных систем
- Дальнейшие оптимизации

Вопросы?

Спасибо!