

Параллельное решение систем РМГ на графических процессорах

Копысов С.П., Новиков А.К., Сагдеева Ю.А.

Институт прикладной механики УрО РАН

Семинар: “Решение инженерных и научных задач на гибридных вычислительных системах, графические процессоры и архитектура CUDA”
Институт математики и механики УрО РАН, Екатеринбург,
24 марта 2011 г.

- 1 Метод Галёркина с разрывными базисными функциями (PMГ)
 - Достоинства и недостатки PMГ
 - PMГ для задачи теории упругости
 - Формирование системы уравнений CPMГ
 - Структура и свойства матрицы системы PMГ
- 2 Тестовая задача
- 3 Решение систем разрывного метода Галёркина
 - Прямой и итерационный методы на GPU
 - Методы решения систем PMГ
 - Предобусловливатели
 - Аппаратное обеспечение
- 4 Вычислительные эксперименты
 - Решения систем CMГ и CPMГ
 - Форматы хранения матриц и GPU - реализация
 - Решение системы несимметричного PMГ (HPMГ)
- 5 Выводы

Достоинства метода

- использование несогласованных сеток (составные конструкции, композиционные материалы, сопряженные задачи);
- использование комбинированных сеток (разные типы элементов);
- адаптивные схемы (локальное повышение порядка аппроксимации и/или престроение сетки);
- большой потенциал распараллеливания (декомпозиция области, параллельные адаптивные схемы).

Недостатки

- Увеличение размера конечно-элементной СЛАУ
- Необходимость выбора штрафного параметра
- Зависимость обусловленности СЛАУ от штрафного параметра

Предполагаемая область применения

- Моделирование напряженно-деформированного состояния в сложных (составных) конструкциях.
- Исследование напряженно-деформированного состояния конструкций в условиях длительной эксплуатации с накоплением повреждения материала.
- Получение эффективных характеристик композиционных материалов.
- Сопряженные задачи механики деформируемого твердого тела и газодинамики.

Формулировка РМГ по методу внутреннего штрафа для задачи теории упругости

Пусть $\tilde{\Omega}$ — разделение области Ω на M элементов K_i , таких что $\cup_{i=1}^M K_i = \tilde{\Omega}$, $K_i \cap K_j = \emptyset$. $\tilde{\Gamma}$ — совокупность внутренних ребер между элементами. Γ — внешняя граница области Ω .

Найти функцию $u^h \in U^h$ такую, что для всех $\omega^h \in W^h$

$$\int_{\tilde{\Omega}} \nabla^s \omega^h : C : \nabla^s u^h d\Omega + \theta_{DG} \int_{\tilde{\Gamma}} \langle \nabla^s \omega^h : C \rangle n_K \cdot \llbracket u^h \rrbracket d\Gamma - \int_{\tilde{\Gamma}} \llbracket \omega^h \rrbracket \cdot \langle C : \nabla^s u^h \rangle n_K d\Gamma + \int_{\tilde{\Gamma}} \llbracket \omega^h \rrbracket \eta \llbracket u^h \rrbracket d\Gamma = \int_{\tilde{\Omega}} \omega^h \cdot g d\Omega + \int_{\Gamma^N} \omega^h \cdot f^N d\Gamma, \quad (1)$$

здесь u^h — пробная функция; $\eta \geq C_1 h^{-\beta}$ — штраф в скачке перемещений $\llbracket u^h \rrbracket$ между элементами; $\beta \geq 1/(d-1)$ — параметр, зависящий от размерности задачи; θ_{DG} — параметр, определяющий метод штрафа: $\theta_{DG} = -1$ симметричный РМГ с внутренним штрафом (СРМГ); $\theta_{DG} = 1$ несимметричный РМГ с внутренним штрафом (НРМГ).


Оператор среднего $\langle u^h \rangle := \frac{1}{2} (u_1^h + u_2^h)$ на $\tilde{\Gamma}$, $\langle u^h \rangle := u^h$ на Γ .

Оператор скачка $\llbracket u^h \rrbracket := u_1^h - u_2^h$ на $\tilde{\Gamma}$, $\llbracket u^h \rrbracket := u^h$ на Γ .

Граничные условия заданы на Γ^D и Γ^N , так что $\Gamma^D \cup \Gamma^N = \Gamma$, $\Gamma^D \cap \Gamma^N = \emptyset$.

Пример формирования СЛАУ симметричного РМГ

Нумерация узловых неизвестных в стандартном и разрывном методе Галёркина



Матрица жесткости в симметричном разрывном методе Галёркина (СРМГ)

$$A = \begin{bmatrix} \int_{K_1} B_{e=1}^T C B_{e=1} d\Omega \\ \int_{K_2} B_{e=2}^T C B_{e=2} d\Omega \end{bmatrix} - \int_{\tilde{\Gamma}} (B_I^{< >})^T \phi_I^{\llbracket \cdot \rrbracket} d\Gamma - \int_{\tilde{\Gamma}} (\phi_I^{\llbracket \cdot \rrbracket})^T B_I^{< >} d\Gamma + \int_{\tilde{\Gamma}} (\phi_I^{\llbracket \cdot \rrbracket})^T \eta \phi_I^{\llbracket \cdot \rrbracket} d\Gamma = A_0 - A_d - A_s + A_r, \quad (2)$$




Рис. 1: Вклад элементных матриц A_0




Рис. 2: Вклад интегралов по границе $-A_d - A_s + A_r$




Рис. 3: Глобальная матрица СРМГ $A = A_0 - A_d - A_s + A_r$ ($N = 16$, $Nnz = 192$)




Рис. 4: Структура матрицы A для СМГ ($N = 12$, $Nnz = 112$)




Рис. 5: Структура матрицы A для CRMG ($N = 16$, $Nnz = 192$)

Система уравнений

$$Au = f. \quad (3)$$

Свойства матрицы системы РМГ

- $u^T Au \geq 0, \forall u$
- $A_{N \times N} = A_{N \times N}^T$ для CRMG
и $A_{N \times N} \neq A_{N \times N}^T$ для НРМГ.
- $Nnz \ll N^2$
- $N_{\text{PMG}} > N_{\text{CMG}}$
- $k(A) \sim \mathcal{O}(h^{-2})$

Тестовая задача

Область радиуса $b = 200$,
с включением радиуса $a = 5$.

Характеристики материала:

$E_1 = 1$, $E_2 = 1$, $\nu_1 = 0.3$, $\nu_2 = 0.25$.

Граничные условия:

$$u_r|_{r=a} = a, u_\theta|_{r=a} = 0.$$





Рис. 6: Расчётная сетка
(1216 конечных элементов, 1305 узлов)

Обусловленность систем РМГ в зависимости от N и параметра η



Экономичные (гибридные) методы решения

- Прямые методы (на основе LU , LL^T , LDL^T разложений матрицы A);
- Итерационные методы крыловского типа (CG, GMRES, BiCGSTAB, ...);
- Гибридные методы:
 - Прямые методы с итерационным уточнением;
 - Итерационные методы крыловского типа с предобуславливанием на основе неполного разложения A (ILU/CG, IC(0)/CG, ...);
 - Методы декомпозиции — метод дополнения Шура (прямой метод — в подобластях, итерационный метод — на границе подобластей).

Сравнение прямого и итерационного методов решения на GPU

Таблица 1: Решение систем СМГ

| Размер системы N | Время, сек | | | $\ u - u_{LU}\ /\ u_{LU}\ $ | |
|-----------------------|------------|-------|---------|-----------------------------|-----------------------|
| | LU | CG | DIAG/CG | CG | DIAG/CG |
| 952 | 0.039 | 0.077 | 0.065 | 2.61×10^{-8} | 2.76×10^{-8} |
| 2568 | 0.260 | 0.147 | 0.114 | 2.82×10^{-8} | 3.58×10^{-8} |
| 4960 | 1.063 | 0.236 | 0.188 | 6.08×10^{-8} | 4.9×10^{-8} |
| 7640 | 3.380 | 0.306 | 0.243 | 6.44×10^{-8} | 6.1×10^{-8} |
| 100660 | — | 2.384 | 1.807 | — | — |

Таблица 2: Решение систем СРМГ

| Размер системы N | Время, сек | | | $\ u - u_{LU}\ /\ u_{LU}\ $ | |
|-----------------------|------------|--------|---------|-----------------------------|-----------------------|
| | LU | CG | DIAG/CG | CG | DIAG/CG |
| 1042 | 0.042 | 4.72 | 2.71 | 2.23×10^{-9} | 1.01×10^{-8} |
| 2426 | 0.217 | 5.83 | 3.29 | 3.46×10^{-9} | 1.80×10^{-8} |
| 4758 | 0.922 | 8.56 | 4.80 | 6.28×10^{-9} | 2.54×10^{-8} |
| 7390 | 2.881 | 12.73 | 7.21 | 1.06×10^{-8} | 2.85×10^{-8} |
| 100866 | — | 147.80 | 80.99 | — | — |

Для симметричных систем РМГ (СРМГ):

- метод сопряженных градиентов (CG) с предобуславливанием;
- прямые и гибридные методы на основе LL^T и LDL^T разложения A .

Для несимметричных систем (НРМГ):

- метод бисопряженных градиентов (BiCGSTAB)
- метод обобщенных минимальных невязок (GMRES)
- прямые и гибридные методы на основе LU разложения A .

Параллельный алгоритм CG с предобуславливанием

```

 $u, r, p, q, z \in \mathbb{R}^{N_1}, A, M^{-1} \in \mathbb{R}^{N_1 \times N_1}, N_1 = N/\sqrt{P}$ 
 $i \leftarrow 0, u_i \leftarrow 0, r_i \leftarrow f$ 
 $z_i \leftarrow M^{-1}r_i$  или решение  $Mz_i = r_i$ 
 $p_i \leftarrow z_i$ 
 $\rho_i \leftarrow (r_i, z_i)$  {здесь и далее  $(\cdot, \cdot) = \sum_P (\cdot, \cdot)^{(P)}$ }
while  $\|r_i\|_2 / \|f\|_2 > \varepsilon$  do
     $q_i \leftarrow Ap_i$  {предполагает, что  $q_i \leftarrow \sum_{P_j=1}^{N_1} A^{(P_j)} p_i$ }
     $\alpha_i \leftarrow (r_i, z_i) / (q_i, p_i)$ 
     $u_{i+1} \leftarrow u_i + \alpha_i p_i$ 
     $r_{i+1} \leftarrow r_i - \alpha_i q_i$ 
     $z_{i+1} \leftarrow M^{-1}r_{i+1}$  или решение  $Mz_{i+1} = r_{i+1}$ 
     $\rho_{i+1} \leftarrow (r_{i+1}, z_{i+1})$ 
     $\beta_{i+1} \leftarrow \rho_{i+1} / \rho_i$ 
     $p_{i+1} \leftarrow z_{i+1} + \beta_{i+1} p_i$ 
     $i \leftarrow i + 1$ 
end while

```

Явные предобусловливатели $M^{-1} \approx A^{-1}$

AINV — основан на неполной факторизации обратной матрицы в виде $M^{-1} = ZD^{-1}Z^T \approx A^{-1}$, где $Z \approx L^{-T}$ из $A = LDL^T$.

SPAI — получается в процессе минимизации нормы Фробениуса $\min \|I - M^{-1}A\|_F < \varepsilon$, здесь ε — заданная точность.

DIAG — диагональный предобусловливатель $M^{-1} = \text{diag}(A)^{-1}$.

Неявные предобусловливатели $M \approx A$

ILU — неполная LU(p, τ)-факторизация, где p — максимальное число внедиагональных элементов в неполном LU-разложении, τ — порог отбрасывания внедиагональных элементов в предобусловливателе.

AMG — сглаживающий агрегирующий алгебраический многосеточный метод

Распараллеливание метода решения

- Параллельная реализация матрично-векторного произведения $q_i \leftarrow Ap_i$ при компактном хранении матрицы (форматы COO, CRS, ELL, BCRS2, ...).
- Использование библиотек линейной алгебры (MKL, ACML, ATLAS, GOTO, CUBLAS).
- Построение предобуславливателя.
 - Последовательное построение предобуславливателя на CPU (M_{CPU}).
 - Параллельное построение предобуславливателя на CPU (M_{MCP}).
 - Параллельное построение предобуславливателя на GPU (M_{GPU}).
- Операции предобуславливания
 - Явное предобуславливание $z_i \leftarrow M^{-1}r_i$.
 - последовательное на CPU (M_{CPU}).
 - параллельное на CPU (M_{MCP}).
 - параллельное предобуславливание на GPU (M_{GPU}).
 - Неявное предобуславливание $Mz_i = r_i$.
 - последовательное на CPU.
 - параллельное на CPU.
 - параллельное предобуславливание на GPU.




Рис. 7: Архитектуры CPU и GPU




Рис. 8: Видеокарта GeForce 470GTX

Таблица 3: Характеристики аппаратного обеспечения

| Характеристика | GPU | CPU |
|-----------------------|----------------------|------------------------|
| Процессор | NVIDIA GF100 rev. A3 | AMD Athlon 64 X2 5600+ |
| Число процессоров | 1 | 1 |
| Число ядер | 448 | 2 |
| Тактовая частота, ГГц | 1.22 | 1.00 |
| Память индив., Мбайт | 1280 | 1 |
| Память ОЗУ, Мбайт | 2048 | 2048 |

Решение систем стандартного метода Галёркина и симметричного РМГ

Таблица 4: Время построения предобуславливателя/решение системы и число итераций

| Метод | СМГ | | СРМГ | | |
|---------------------|--------------------------------------|---------------------------------------|---------------------------------------|--|-----------------------|
| | $N = 2416$ | | $N = 9346$ | | $N = 100866$ |
| | CPU | GPU | CPU | GPU | GPU |
| CG | 0.36 (169) | 0.04 (171) | 130.08 (35901) | 10.97 (35901) | 147.8 (74053) |
| DIAG/CG | 0.12 (149) | 0.03 (150) | 50.29 (13416) | 4.31 (13416) | 80.9911 (39697) |
| AINV/CG | 0.16/0.144 (81) | | 6.02/82.5 (28583) | | 4.54/93.33 (26225) |
| SPAI/CG | 0.01/0.06 (99) | | 0.06/— ($> 10^5$) | | |
| AMG/CG | 0.02/0.09 (30) | 0.02/0.03 (30) | 0.05/57.72 (5529) | 0.05/7.84 (5529) | 0.24/80.8 (22057) |
| ILU(p, τ)/CG | (20, 10^{-6}) 0.59/0.4 (46) | (20, 10^{-6}) 0.56/0.56 (46) | (80, 10^{-8}) 15.6/3.18 (17) | (80, 10^{-8}) 16.45/2.18 (17) | |

Форматы сжатого хранения матриц

- COO (Координатный формат) — хранятся упорядоченные по строкам значения $a_{ij} \neq 0$ и их строчные i и столбцовые индексы j ;
- CRS (Сжатый строчный формат) — вместо строчных индексов хранятся указатели на начальные позиции каждой строки в списках $a_{ij} \neq 0$ и j);
- BCRS2 (Блочный вариант CRS) — используются блоки 2×2 ;
- ELL — формат с постоянным числом ненулевых элементов в строке;
- HYB (Гибридный) — комбинация ELL и формата COO.

Таблица 5: Время решения при различных форматах хранения матриц

| Формат матрицы | CG | | DIAG/CG | |
|----------------|--------|-------|---------|-------|
| | CPU | GPU | CPU | GPU |
| CRS | 130.08 | 28.27 | 50.29 | 11.08 |
| BCRS2 | | 15.82 | | 6.51 |
| COO | | 10.97 | | 4.31 |
| HYB | | 6.99 | | 3.13 |
| ELL | | 6.41 | | 2.93 |

Таблица 6: Решение несимметричной системы РМГ, $N = 9346$

| Метод | CPU | GPU |
|----------------------------------|-------------------|-------------------|
| ILU(45, 10^{-8})/ GMRES | 7.62/5.48 (50) | 8.24/3.95 (50) |
| ILU(45, 10^{-8})/ BICGSTAB | 7.62/4.65 (22) | 8.24/3.31 (22) |

- Для эффективного решения систем РМГ на графических ускорителях процесс построения предобусловливателя должен быть распараллелен.
- В итерационном процессе, выполняемом на GPU предпочтительно применение явных предобусловливателей.
- Необходимым условием для получения максимального ускорения вычислений на GPU является соответствие формата хранения матриц архитектуре графического ускорителя.
- При увеличении размерности решаемых систем уравнений предполагается рассмотрение вариантов: multiGPU, multiGPU/multiCPU.