



НИЖЕГОРОДСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМ. Н.И. ЛОБАЧЕВСКОГО
ИНСТИТУТ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ, МАТЕМАТИКИ И МЕХАНИКИ
КАФЕДРА ВЫСОКОПРОИЗВОДИТЕЛЬНЫХ ВЫЧИСЛЕНИЙ И СИСТЕМНОГО ПРОГРАММИРОВАНИЯ
ЛАБОРАТОРИЯ ITLav



НИЖЕГОРОДСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ им. Н.И. ЛОБАЧЕВСКОГО
ИНСТИТУТ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ, МАТЕМАТИКИ И МЕХАНИКИ
КАФЕДРА ВЫСОКОПРОИЗВОДИТЕЛЬНЫХ ВЫЧИСЛЕНИЙ И СИСТЕМНОГО ПРОГРАММИРОВАНИЯ
ЛАБОРАТОРИЯ ITLAB

***ВВЕДЕНИЕ В АНАЛИЗ ПРОИЗВОДИТЕЛЬНОСТИ
И ОПТИМИЗАЦИЮ ПРОГРАММ***

**Ускорение решения уравнений Максвелла
методом FDTD с использованием вычислений
в смешанной точности**



**LOBACHEVSKY
UNIVERSITY**

Арисова А.Н., Волокитин В.Д., Мееров И.Б.

Содержание

- Цель лекции
- Постановка задачи
- Метод конечных разностей во временной области
- Алгоритм
- Результаты вычислительных экспериментов
- Выводы

Цель лекции

- Продемонстрировать возможности использования вычислений в смешанной точности для ускорения расчетов в вычислительных науках

Что вы знаете про вычисления в смешанной точности?

Уравнения Максвелла

- **Уравнения Максвелла** — система уравнений в дифференциальной форме, описывающих электромагнитное поле, его связь с электрическими зарядами и токами в вакууме и в сплошных средах.

$$\frac{\partial \mathbf{D}}{\partial t} = \nabla \times \mathbf{H} - 4\pi \mathbf{j} \quad (1)$$

+

Уравнение непрерывности

$$\frac{\partial \rho}{\partial t} + \nabla \cdot \mathbf{j} = 0$$

$$\frac{\partial \mathbf{B}}{\partial t} = -\nabla \times \mathbf{E} \quad (2)$$

+

Материальные уравнения

(Среда моделирования-
вакуум)

$$\mathbf{D} = \mathbf{E} \text{ и } \mathbf{B} = \mathbf{H}$$

$$\nabla \cdot \mathbf{D} = 4\pi \rho \quad (3)$$

$$\nabla \cdot \mathbf{B} = 0 \quad (4)$$




$$\begin{cases} \frac{\partial \mathbf{E}}{\partial t} = \nabla \times \mathbf{B} - 4\pi \mathbf{j} \\ \frac{\partial \mathbf{B}}{\partial t} = -\nabla \times \mathbf{E} \end{cases}$$

Метод конечных разностей во временной области (FDTD)

Метод FDTD основан на **дискретизации уравнений Максвелла** с помощью разностных **аппроксимаций** пространственных и временных **частных производных**

Сетка Yee





$$\left. \frac{\partial E_z^n}{\partial y} \right|_{i,j,k} = \frac{E_z^n|_{i,j+1,k} - E_z^n|_{i,j,k}}{dy}$$

$$\left. \frac{\partial E_z^n}{\partial t} \right|_{i,j,k} = \frac{E_z^{n+1}|_{i,j,k} - E_z^n|_{i,j,k}}{dt}$$

Поглощающие граничные условия (PML)

Для моделирования свободного пространства при решении неограниченных электромагнитных задач методом конечных разностей во временной области должны использоваться особые поглощающие граничные условия.



Адаптировано из Berenger, J. *Computational Physics*, 1994, pp. 185-200.

Идея

□ **Основная идея** — выполнять в половинной точности наиболее вычислительно-трудоемкие расчеты, а одинарную или двойную точность использовать для подсчета и уменьшения ошибок вычислений, добившись ускорения вычислений при сохранении приемлемой точности

□ **Вопросы:**

- Какие этапы вычислений нужно выполнять в половинной точности?
- Какие возникают проблемы и как их решать?
- Какой точности удастся достигнуть?
- На какое ускорение рассчитывать, при условии что в современном оборудовании происходит расширение поддержки типов данных пониженной точности?


Реализации метода FDTD с PML

- ❑ Реализаций метода FDTD существует довольно много, но вопрос об использовании смешанной точности остается открытым.
- ❑ Среди них есть *бесплатные пакеты* программного обеспечения с открытым исходным кодом, например:
 - **Meep** – высокоэффективный пакет FDTD, разработанный в Массачусетском технологическом институте;
 - **gprMax** – программное обеспечение из Эдинбургского университета;;
 - **OpenEMS** – бесплатный решатель, разработанный в Университете Дуйсбург-Эссен, использует расширенный интерфейс Matlab (или Octave) для определения опций FDTD.

Реализации метода FDTD с PML

- Также разработаны *коммерческие пакеты* программного обеспечения для моделирования метода FDTD:
 - **Ansys Lumerical FDTD** – продукт компании Ansys для моделирования нанофотонных устройств, процессов и материалов с помощью точно настроенной реализации метода FDTD;
 - **XFdtd® 3D EM Simulation Software [14]** – инновационный полнофункциональный решатель для электромагнитного моделирования компании Remcom.
- Разработки ННГУ и ИПФ РАН для суперкомпьютерного моделирования лазерной плазмы методом частиц в ячейках:
 - PICADOR (C++)
 - Hi-Chi (Python + C++)
- В данной лекции рассматривается отдельный код – реализация FDTD и PML


Выбор режима точности (типов данных)



- Выделим три области
- Введем два шаблонных параметра:
- **f_{type}** – тип данных для вычислений в основной расчетной области (**желтые ячейки**)
- **f_{typePML}** – тип данных для вычислений в области гран. условий PML (**зеленые ячейки**)
- **f_{typeGenerator}** – тип данных для генератора полей, *всегда в двойной точности* (серые ячейки). **f_{typeGenerator} = double**

- Хотелось бы все считать в половинной точности, но не получится добиться приемлемых результатов
- Нужно экспериментировать!

Выбор режима точности (типов данных)



- ❑ **ftype** – тип данных для вычислений в основной расчетной области (**желтые ячейки**)
- ❑ **ftypePML** – тип данных для вычислений в области гран. условий PML (**зеленые ячейки**)
- ❑ **ftypeGenerator** – тип данных для генератора полей, *всегда в двойной точности* (серые ячейки). **ftypeGenerator = double**

- ❑ Было изучено, какие вычисления можно проводить в пониженной точности, определено, что оказывает существенное влияние на точность результатов
- ❑ Выяснилось, что порядок операций критически важен при расчетах в пониженной точности
- ❑ Наибольшие потери при суммировании: **алгоритм Кэхэна** может помочь

Суммирование с компенсацией (алгоритм Кэхэна)

- Уильям (Вольф) Кэхэн – лауреат премии Тьюринга, один из авторов концепции представления чисел с плавающей запятой в стандарте IEEE-754

- **Алгоритм суммирования с компенсацией:**

```
fctype KahanSum(fctype input[], size_t n) {  
    fctype sum, c, y, t; sum = c = 0.0;  
    for (size_t i = 0; i < n; i++) {  
        y = input[i] - c;  
        t = sum + y;  
        c = (t - sum) - y;  
        sum = t;  
    }  
    return sum;  
}
```




Фото из Wikipedia

Программная реализация на Data Parallel C++ (SYCL)

Реализация на DPC++. Основной алгоритм

```
int Nx = 32, Ny = 32, Nz = 32;           // Размеры сетки
int delta_x = 4, delta_y = 4, delta_z = 4; // Размеры PML-слоя
int Nt = 5000;                           // Количество шагов интегрирования
double dx = 0.05, dy = 0.05, dz = 0.05;  // Пространственные шаги интегрирования
double dt = 0.005;                       // Шаг интегрирования по времени
```



Программная реализация на Data Parallel C++ (SYCL)

Реализация на DPC++. Основной алгоритм

```
q.submit([&](handler& h) {  
    h.parallel_for(sycl::range<3>(Nx+2delta_x,Ny+2delta_y,Nz+2delta_z), [=](auto index){  
        int i = index[0] + 1;  
        int j = index[1] + 1;  
        int k = index[2] + 1;  
        if (i>delta_x&&i<Nx+delta_x && j>delta_y&&j<Ny+delta_y&&k>delta_z&&k<Nz+delta_z)  
            UpdateElectric();  
        else  
            UpdateElectricPML();  
    });}).wait_and_throw();
```

```
q.submit([&](handler& h) {  
    h.parallel_for(sycl::range<3>(Nx+2delta_x,Ny+2delta_y,Nz+2delta_z), [=](auto index){  
        int i = index[0] + 1;  
        int j = index[1] + 1;  
        int k = index[2] + 1;  
        if (i>delta_x&&i<Nx+delta_x && j>delta_y&&j<Ny+delta_y &&k>delta_z&&k<Nz+delta_z)  
            UpdateMagnetic();  
        else  
            UpdateMagneticPML();  
    });}).wait_and_throw();
```

```
it++;
```

Модельная задача

Тестовая задача с заданием источников в виде граничных условий

- Начальные условия**

$$\mathbf{E} = (0, 0, 0)^T, \quad \mathbf{B} = (0, 0, 0)^T$$

- Расчетная область $[0, 4\pi] \times [0, 16\pi] \times [0, 16\pi]$

- $N_x = 256, N_y = N_z = 128, \Delta t = 1/512$

- Граничные условия PML, толщина слоя $\delta = 8, \sigma = 46.5, n = 4$


- Задание источников**

$$E_y^n(i^*, j, k) += 4\pi\Delta t * J_y^{electric}(i^*, j, k, n)$$

$$B_z^n(i^*, j, k) += 4\pi\Delta t * J_z^{magnetic}(i^*, j, k, n)$$

$$J_y^{electric}(i^*, j, k, n) = \exp\left(-\frac{(n\Delta t - t_0)^2}{t_p^2}\right) \exp\left(-\frac{(y_j - y^0)^2}{a_t^2}\right) \exp\left(-\frac{(z_j - z^0)^2}{a_t^2}\right) \cdot \sin(\omega(n\Delta t - t_0) - k(x_{i^*} + \bar{x}))$$

$$J_z^{magnetic}(i^*, j, k, n) = \exp\left(-\frac{((n\Delta t + \bar{t}) - t_0)^2}{t_p^2}\right) \exp\left(-\frac{(y_j - y^0)^2}{a_t^2}\right) \exp\left(-\frac{(z_j - z^0)^2}{a_t^2}\right) \cdot \sin(\omega(n\Delta t + \bar{t} - t_0) - kx_{i^*})$$



Методика оценки корректности

- ❑ **Вопрос:** как оценить корректность, что использовать в качестве метрики?
- ❑ Что принять за эталон?
 - *Очевидный ответ:* можно использовать результаты, полученные при расчетах в двойной точности
- ❑ Какую метрику использовать?
 - Абсолютная ошибка
 - Относительная ошибка
- ❑ Каковы недостатки этих метрик в данном случае?
- ❑ В какой точке считать?

Методика оценки корректности


□ Используем следующую метрику (SMAPE):

$$Error_{\text{SMAPE}} = \frac{1}{6 \cdot N_x \cdot N_y \cdot N_z} * \sum_{i,j,k} \sum_{x \in \{E_x, E_y, E_z, B_x, B_y, B_z\}} \frac{2 \cdot |x^* - x|}{|x^*| + |x|}$$

□ Каковы преимущества такого подхода?

Результаты (сравнение с эталоном)


График изменения ошибки SMAPE



- ❑ **Половинный режим точности с суммированием Кэхэна стабильно работает с ошибкой $3 \cdot 10^{-3}$**
- ❑ **В случае без суммирования Кэхэна ошибка на порядок хуже.**

Результаты (уровень поглощения)

График изменения энергии в разных режимах точности



□ Численная характеристика корректности работы метода – **уровень поглощения**, который вычислялся как отношение энергии поля после полного поглощения и энергии исходного поля

Результаты (уровень поглощения)

График изменения энергии в разных режимах точности

— Двойная точность — Одинарная точность
— Половинная точность с суммированием Кэхэна — Половинная точность




Режим точности	Уровень поглощения
Половинная точность	2.81138e-05
Половинная точность с суммированием Кэхэна	1.05449e-06
Одинарная точность	3.00066e-08
Двойная точность	4.09413e-10

$$R = \frac{Energy_N}{Energy_0}$$

$$Energy = \sum_{i,j,k} (|\vec{E}|^2 + |\vec{B}|^2)$$

Анализ производительности на CPU

Сравнение времени работы реализаций на C++ и DPC++ на CPU




- ❑ Размеры сетки:
 $Nx = 256$,
 $Ny = 128$,
 $Nz = 128$
- ❑ Время приведено в **секундах**
- ❑ Реализация на DPC++ добавляет около **15% накладных расходов**

Запуски проводились на сервисе Intel DevCloud на узле суперкомпьютера Endeavour с 2-мя процессорами **Intel Xeon Platinum 8260L** (192 ГБ оперативной памяти, Red Hat 4.8.5, компилятором Intel C++ и Intel DPC++).

Анализ производительности на GPU

Сравнение времени работы реализации на DPC++ на GPU для разных размеров сеток



Запуски проводились на СК “Лобачевский” на GPU NVIDIA A100 (6912 потоковых процессоров, 40 GB HBM2e 1555GB/s)

- ❑ Чем больше размер сетки, тем больше ускорение
- ❑ Много времени занимает расчет PML-слоя. Это приводит к большому числу синхронизаций
- ❑ Было выявлено что **основной ограничивающий фактор это память**
- ❑ **Основные вычислительные ядра в разных точностях соотносились ожидаемо, с двойным ускорением**


Выводы

- ❑ Продемонстрирован подход к организации вычислений в смешанной точности при интегрировании уравнений Максвелла методом конечных разностей во временной области с граничными условиями PML
- ❑ Показано, что при должном внимании к минимизации ошибок, связанных с недостаточной разрешающей способностью типа данных half, удается достигать коэффициента отражения от PML порядка 10^{-6}
- ❑ Запуски на GPU NVIDIA A100 показали, что использование смешанного режима точности (половинная + одинарная) позволяет получить ускорение ~ 1.17 раза относительно одинарной точности и $\sim$ вдвое экономить память GPU
- ❑ Суммирование Кэхэна на порядок повышает точность, но дорого с вычислительной точки зрения
- ❑ Возможные пути дальнейшего ускорения – улучшение работы с памятью (аналог блочного алгоритма)

Литература

Подробнее о данной задаче и методе ее решения:

- Арисова А.Н., Волокитин В.Д., Мееров И.Б. Реализация метода конечных разностей во временной области с использованием вычислений в двойной, одинарной и половинной точности // Суперкомпьютерные дни в России. 21–22 сентября 2020 г., Москва
- Арисова А.Н., Волокитин В.Д., Ефименко Е.С., Мееров И.Б. Реализация метода FDTD с граничными условиями PML с использованием вычислений в смешанной точности// Суперкомпьютерные дни в России. 27–28 сентября 2021 г., Москва
- Арисова А.Н., Волокитин В.Д., Ефименко Е.С., Мееров И.Б. Ускорение решения уравнений Максвелла методом FDTD с использованием вычислений в смешанной точности//Параллельные вычислительные технологии. Санкт-Петербург, 28–30 марта 2023 г.



Контакты

Нижегородский государственный университет

<http://www.unn.ru>

Институт информационных технологий, математики и механики

<http://www.itmm.unn.ru>

Кафедра высокопроизводительных вычислений и системного программирования

