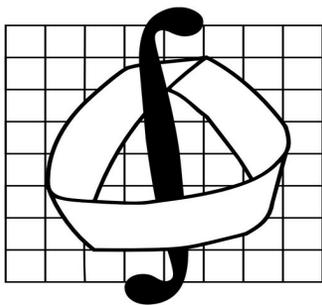


# Методы ускорения программной реализации переноса пассивной примеси на графических ускорителях



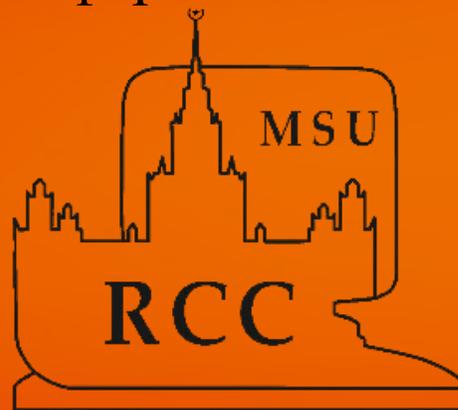
Гащук Е.М.<sup>1,2,3</sup>, Дебольский А.В.<sup>3,4</sup>, Мортиков Е.В.<sup>3,2</sup>

<sup>1</sup>Мехмат МГУ имени М.В. Ломоносова, Москва

<sup>2</sup>Институт Вычислительной математики им. Г.И. Марчука РАН, Москва

<sup>3</sup>НИВЦ МГУ имени М.В. Ломоносова, Москва

<sup>4</sup>Институт физики атмосферы им. А.М. Обухова РАН, Москва



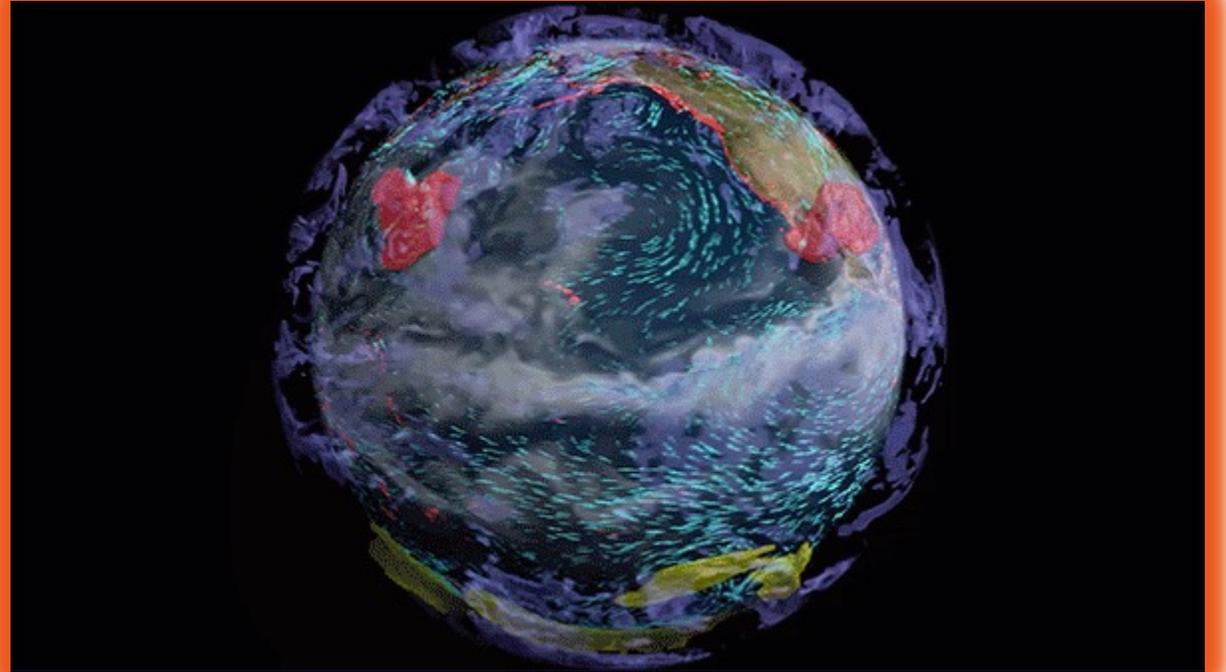
# Зачем?

Расчеты для задач вычислительной гидродинамики, прогноза погоды и климата занимают большое количество времени.

Надо сокращать время вычислений по причине:

- сложность актуальных задач растет (ансамблевые прогнозы, моделирование большого числа примесей, например, реализация распространения аэрозолей и биохимических веществ)
- для актуальных задач необходимо воспроизводить численные эксперименты на сетках большого разрешения

Необходимо разрабатывать вычислительно-эффективные алгоритмы, учитывающие архитектуру суперкомпьютеров



Источник: [Gadhia, Bhoomi, et al.](#)

[Physics-Informed Machine Learning Platform NVIDIA Modulus Is Now Open Source, 23 Feb. 2023](#)

# Как?

Перенос вычислений на графические ускорители и адаптация алгоритмов под современные НРС-системы

Понижение точности вплоть до половинной (поддерживается аппаратно на современных архитектурах GPU)

Аппаратные вычисления в FP16 поддерживаются и для последних поколений CPU (например, Xeon Phi x200 и Skylake-X CPUs)

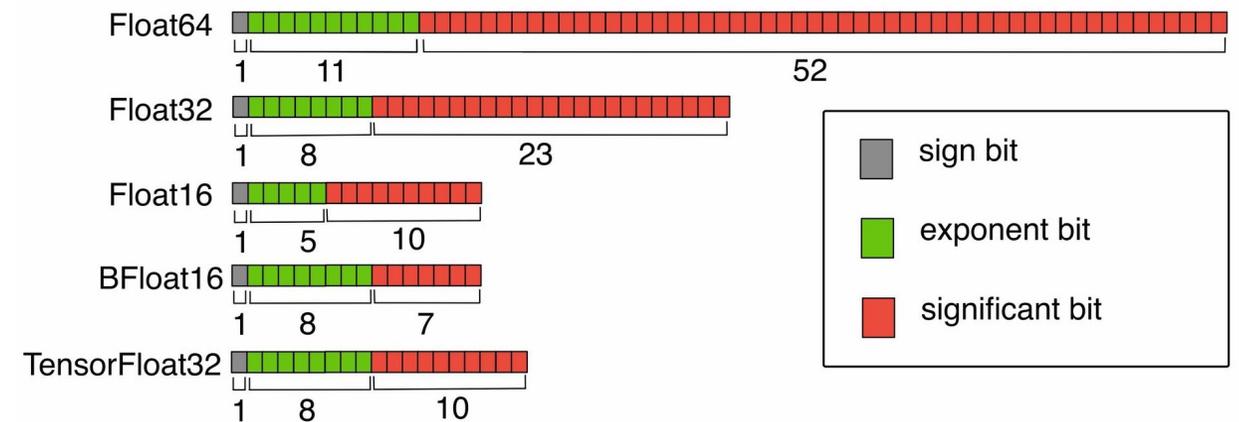


Рис. Битовое представление чисел с плавающей точкой, поддерживаемых современными архитектурами графическими ускорителями NVIDIA

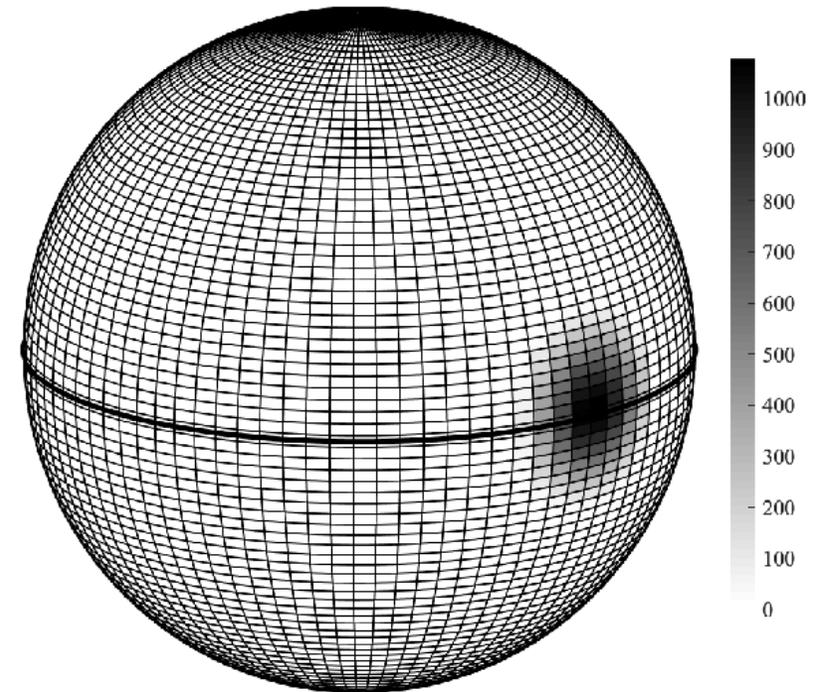
- M. Chantry, T. Thornes, T. Palmer and P. Düben, 2019: Scale-selective precision for weather and climate forecasting Mon. Wea. Rev.
- A. Dawson, P.D. Duben, D.A. MacLeod et al. 2018: Reliable low precision simulations in land surface models Clim Dyn

# Моделирование океана

## Для чего?

- Численные модели общей циркуляции океана являются важным инструментом в исследованиях Земной системы и необходимы для уточнения нашего понимания влияния океана на погоду и климат. Они являются неотъемлемой частью современных моделей прогноза погоды и климата
- Модели океана могут быть использованы для изучения переноса загрязнений, распространения льда, помощи в поисково-спасательных работах
- Сбор данных измерений в океане и проведение натуральных экспериментов, особенно в глубинных слоях, связаны с большими трудностями и высокими затратами

## Перенос концентрации примеси вдоль экватора



**Рис.** Распределение концентрации в начальном состоянии при моделировании переноса пассивной примеси на равномерной сетке в географической системе координат с горизонтальным разрешением  $\Delta\lambda, \theta = 4^\circ$ , жирная линия обозначает экватор

Проблема: для тестов на грубых сетках и ядро CPU, и узел оказались более эффективны, чем один GPU.

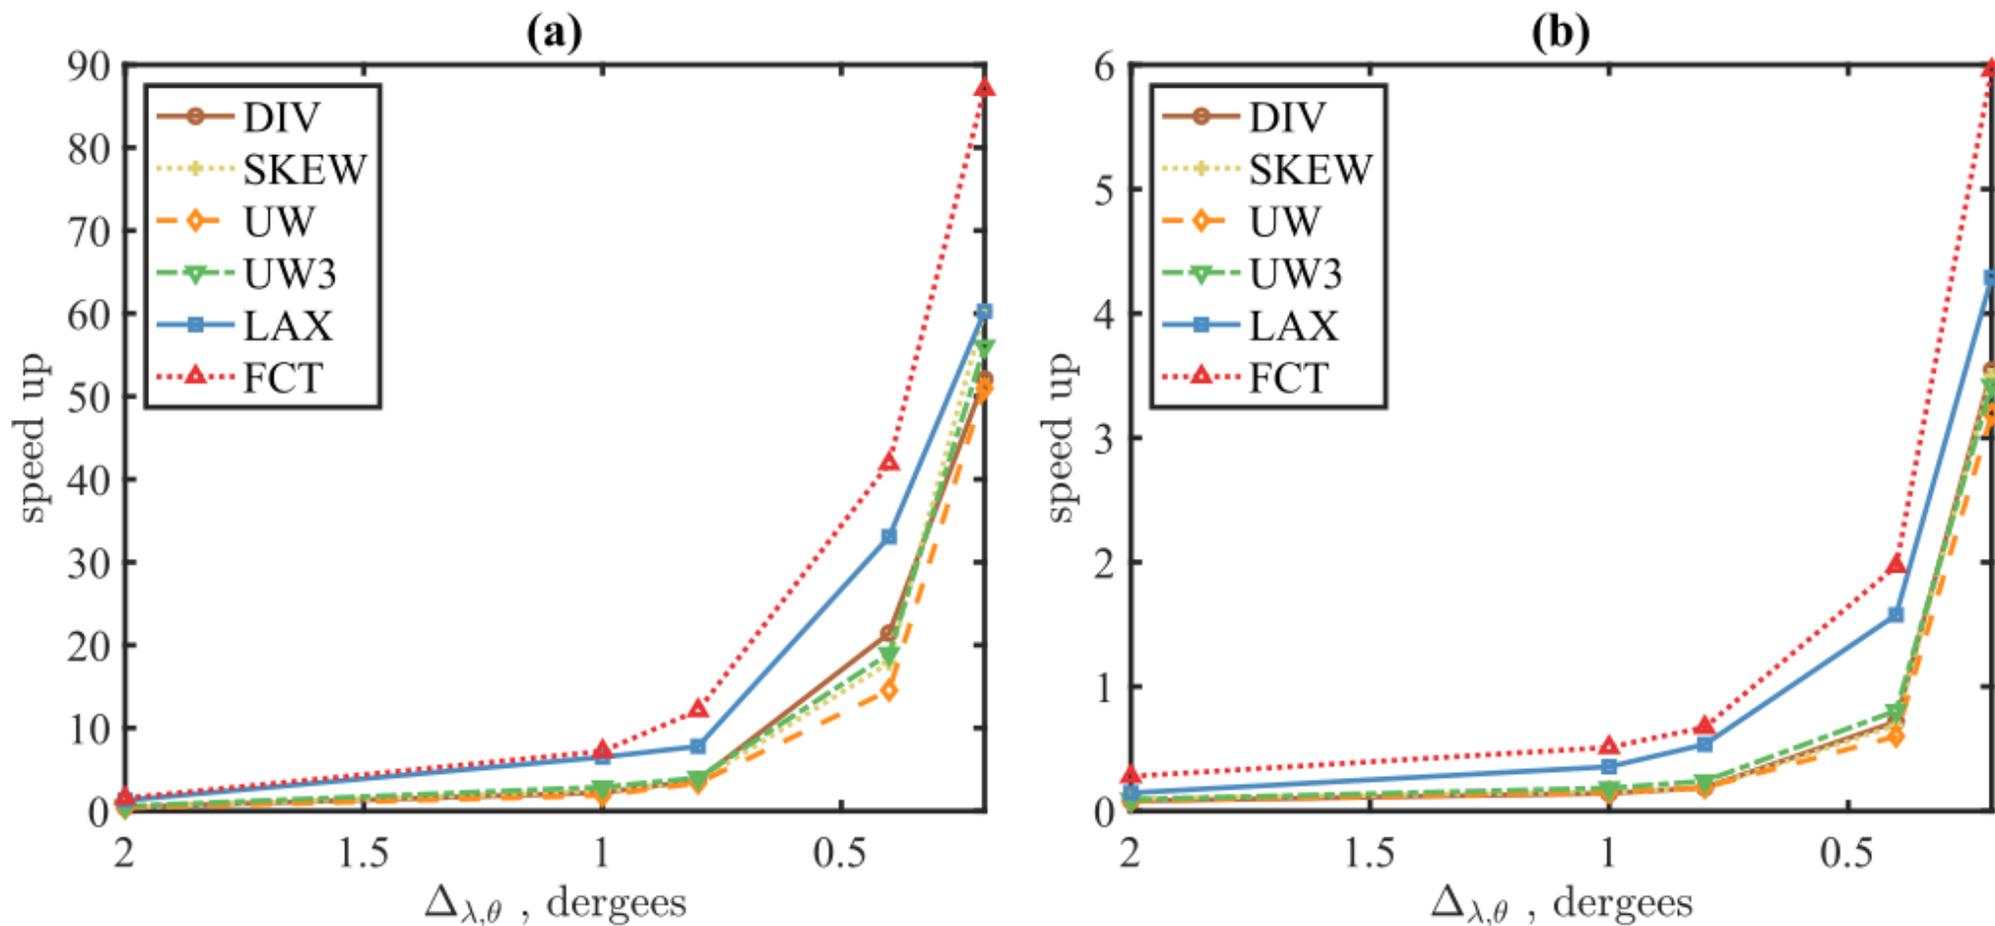


Рис. Ускорение выполнения расчетов переноса примеси на A100 GPU по отношению к CPU- ядру (a) и по отношению к CPU-узлу (b) в зависимости от схемы и горизонтального разрешения для двумерной модели.

# Kernel fusion

---

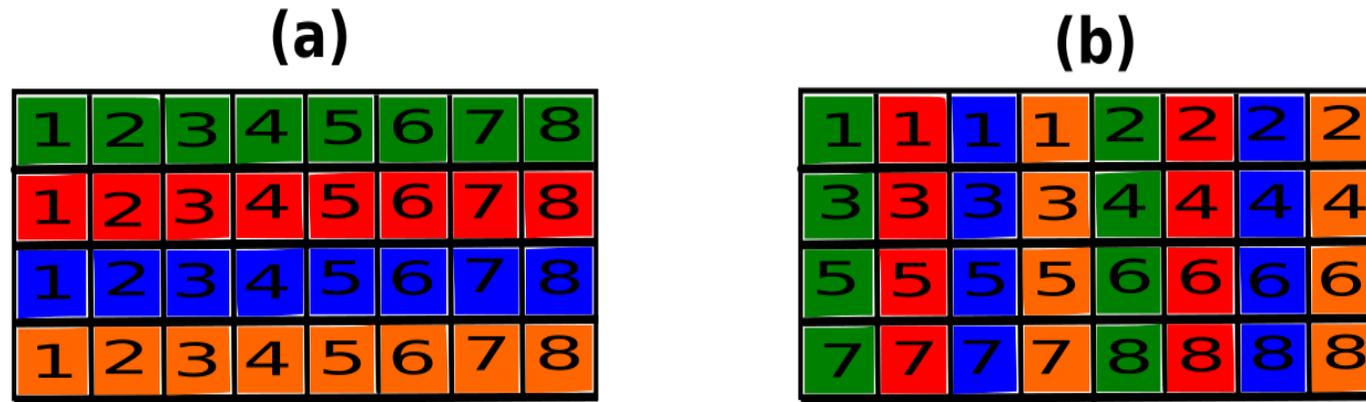
## Kernel fusion

Если между вызовами последовательности ядер нет точек синхронизации, то можно объединить последовательность в одно ядро, избегая многократных вызовов

1.  $(ADV)_k^n = [\nabla \cdot (\mathbf{u}C_k)]_h^n$
2.  $(RHS)_k^n = \frac{23}{12}(ADV)_k^n - \frac{4}{3}(ADV)_k^{n-1} + \frac{5}{12}(ADV)_k^{n-2}$
3.  $C_k^{n+1} = C_k^n + (RHS)_k^n \cdot \Delta t$

В таком виде алгоритм состоит из расчета адвекции **1**, интегрирования по времени **2** и обновления значений концентрации  $C_k$  для  $k$ -го вещества **3** на следующем  $(n + 1)$  шаге по времени. Мы объединили шаги **1** и **2** в одно ядро в случае схем **DIV**, **SKEW** и **UW3**.

# Scalar fusion



**Scalar fusion**

При рассмотрении  $N_c$  примесей вычисления могут быть объединены для улучшения эффективности обращения к памяти. В результате каждый шаг интегрирования по времени выполняется для всего набора примесей вместо  $N_c$  отдельных вычислений для каждой концентрации  $C_k$

**Рис.** Размещение памяти примесей в  $\Phi$ : прямой порядок (a) и с переупорядочиванием (b), число соответствует индексу ячейки вычислительной сетки, цвет - концентрации  $C_k$

Для реализации такого подхода мы объединили массивы, используемые для хранения значений концентрации  $C_k$  в единый вектор состояния полной системы  $\Phi$ . Расположение данных концентрации в  $\Phi$  может быть различным. Мы реализовали этот подход двумя способами в зависимости от размещении памяти k-ой примеси в  $\Phi$  :

1. прямой порядок:  $C_k[m] = \Phi[k \cdot N_g + m]$ ,
2. с переупорядочиванием:  $C_k[m] = \Phi[m \cdot N_c + k]$ ,

где порядок задан для k-го вещества,  $k = 1, \dots, N_c$ , и m-го индекса ячейки вычислительной сетки (сетка состоит из  $N_g = N_x \cdot N_y$  ячеек),  $m = 1, \dots, N_g$ .

# Результаты оценки производительности

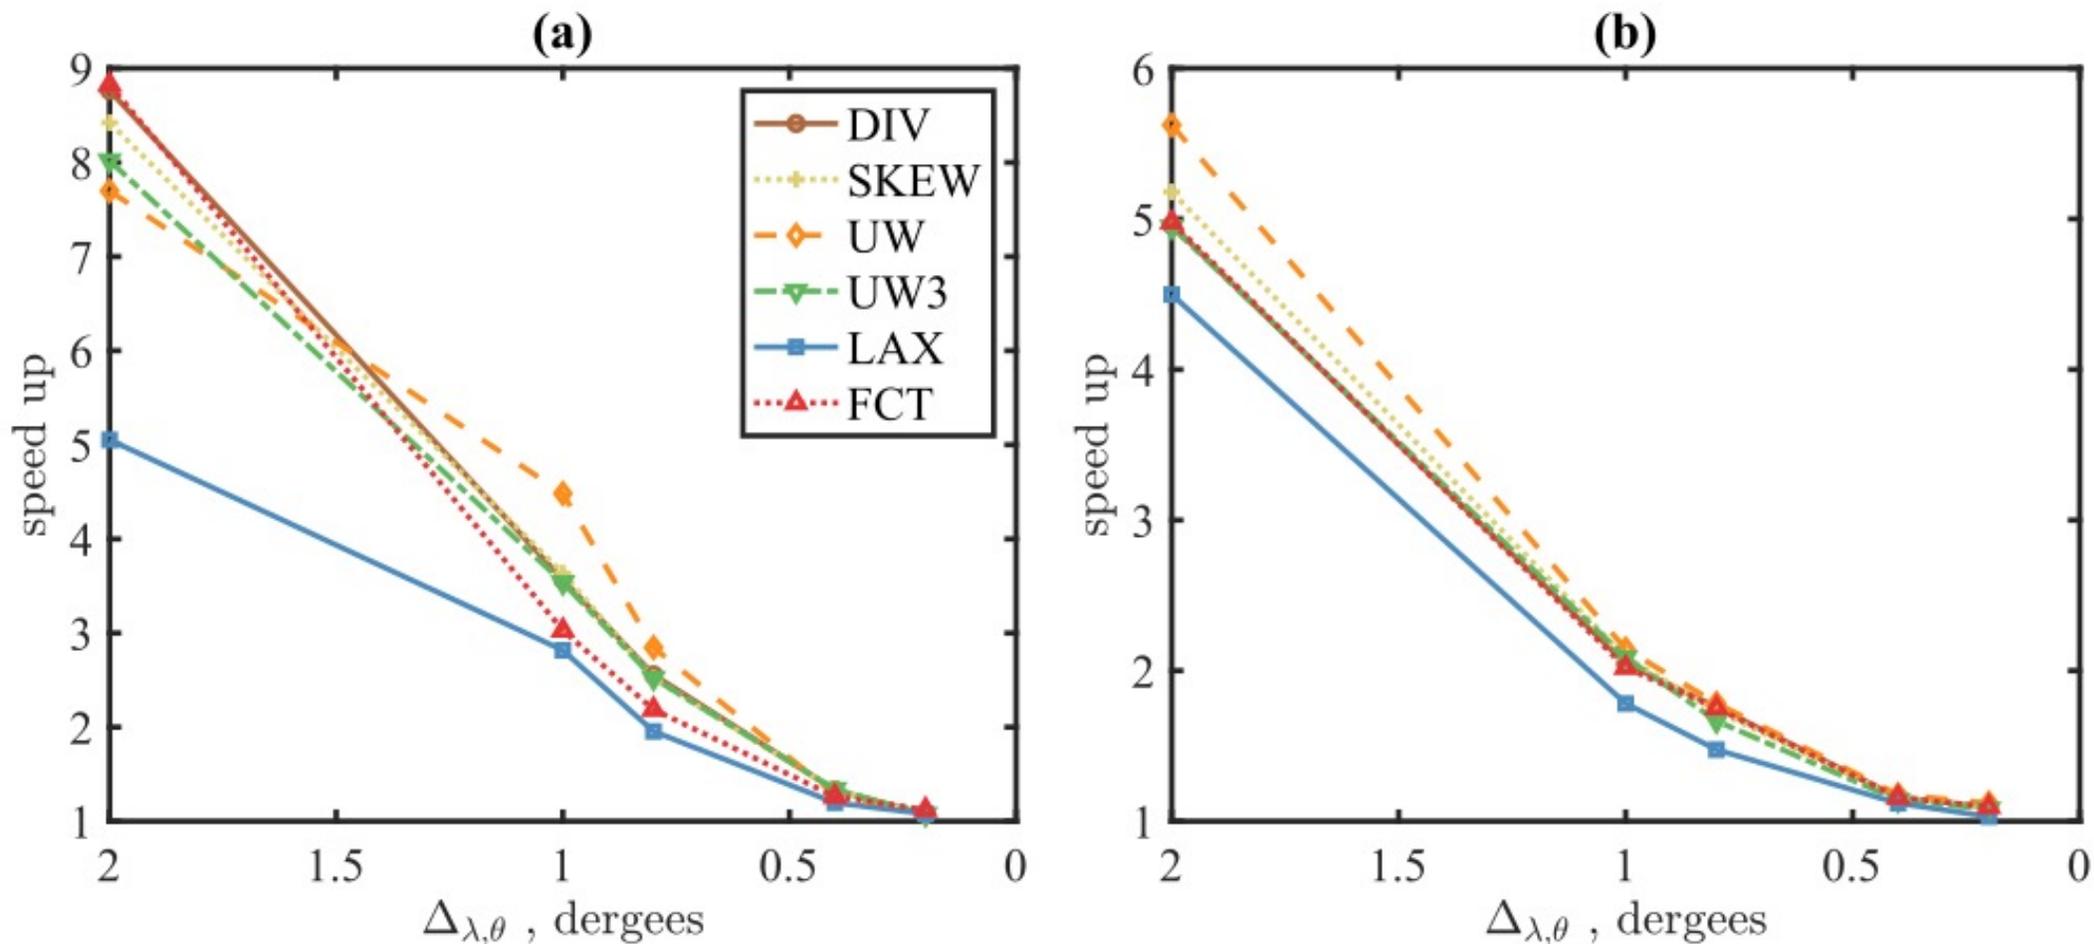


Рис. Ускорение метода *scalar fusion* (прямой порядок) по отношению к базовой реализации для двумерной модели на A100 (a) и V100 (b) GPUs

# Результаты оценки производительности

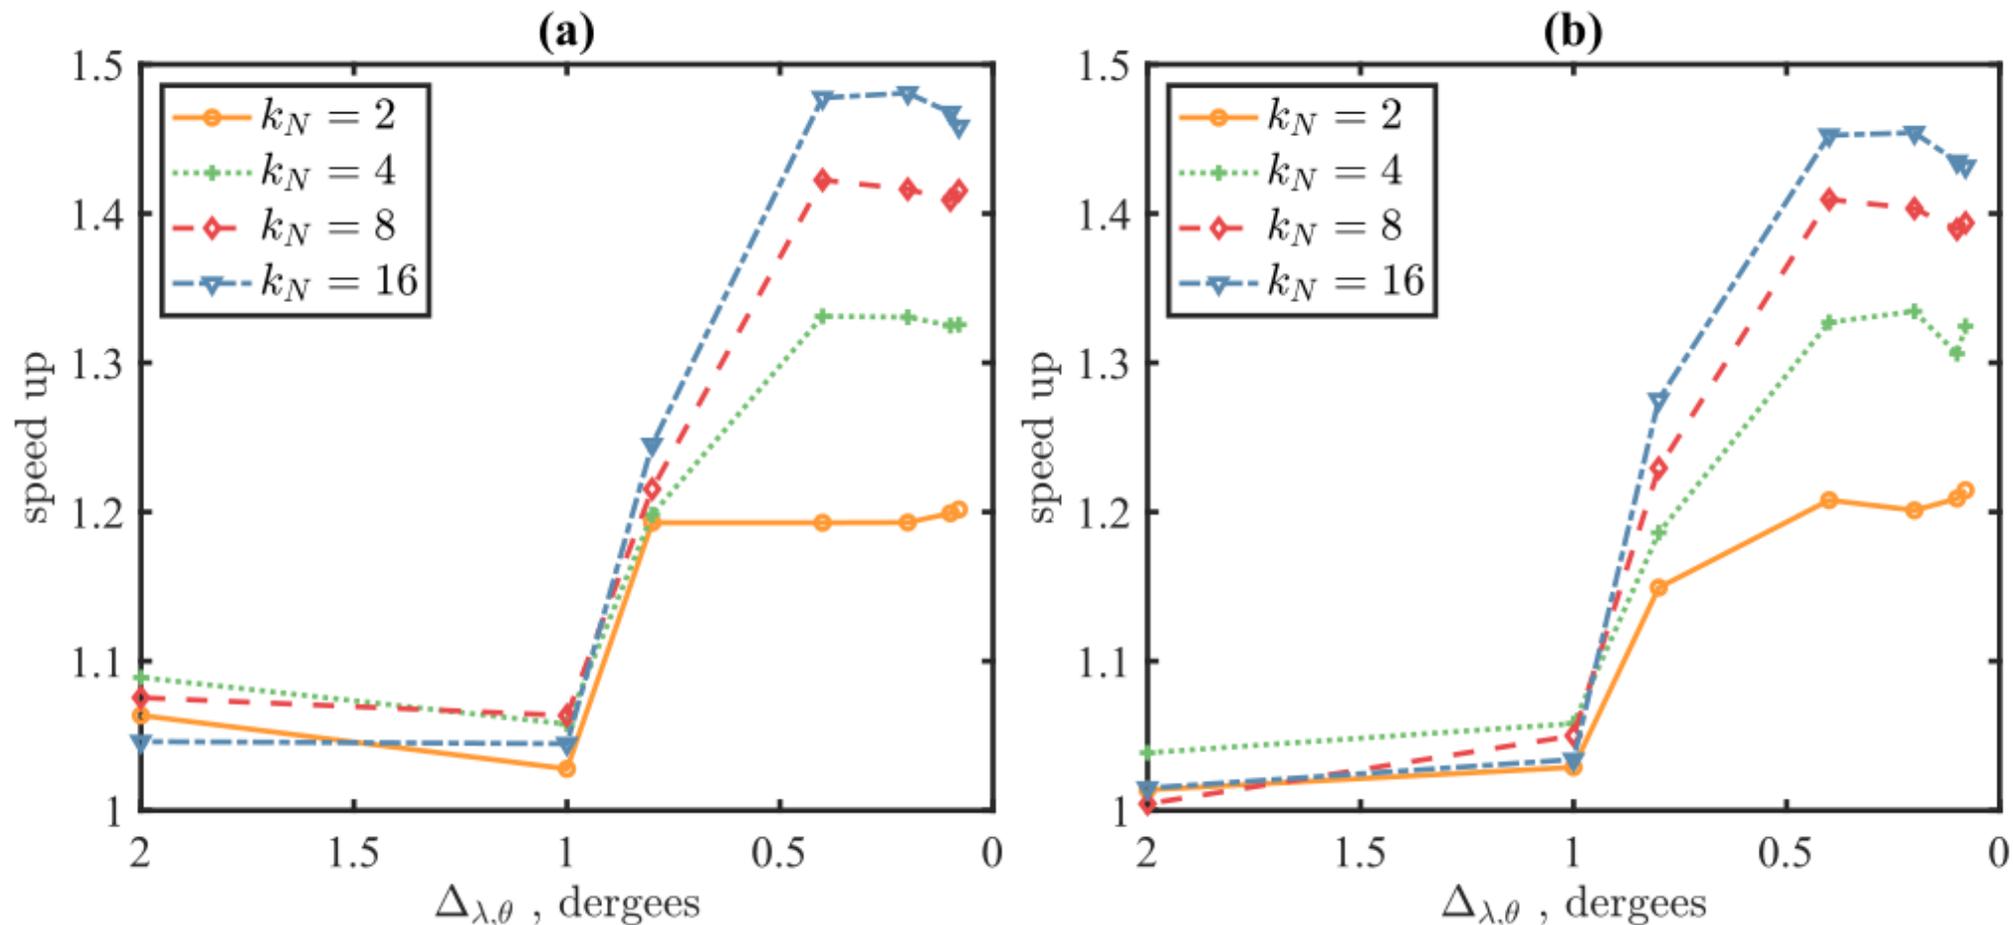


Рис. Ускорение метода *scalar fusion* с переупорядочиванием по отношению к *scalar fusion* с прямым порядком в случае двумерной модели для схем DIV (a) и UW3 (b) на V100 GPU

# Моделирование турбулентных течений

Уравнение переноса:

$$\frac{\partial C}{\partial t} + \frac{\partial u_i C}{\partial x_i} = \frac{1}{Re \cdot Sc} \frac{\partial^2 C}{\partial x_i \partial x_i} - T^{-1} C$$

$$\mathbf{x} = (x_1, x_2, x_3)^T \equiv (x, y, z)^T -$$

пространственные координаты,

$$\mathbf{u}(\mathbf{x}, t) = (u_1, u_2, u_3)^T \equiv (u, v, w)^T -$$

вектор скоростей,

$Re = UH/\nu$  — число Рейнольдса,

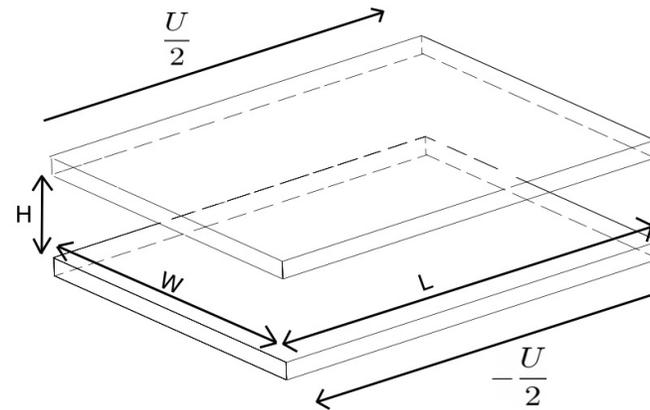
$\nu$  — кинематическая вязкость,  $C$  —

концентрация скаляра,  $Sc = \nu/\xi$  —

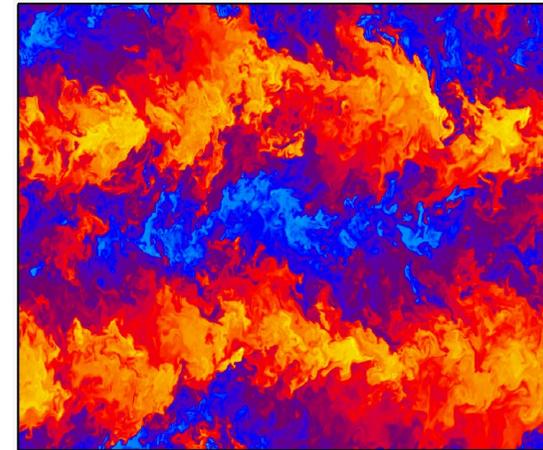
число Шмидта,  $\xi$  — коэффициент

диффузии,  $T$  — время реакции

Турбулентное течение Куэтта — течение между пластинами, движущимися в противоположных направлениях



**Рис.** Течение Куэтта между движущимися пластинами:  $L$ ,  $W$  — продольный и поперечный размеры вычислительной области,  $H$  — высота канала,  $U$  — относительная скорость движения стенок



**Рис.** Продольная компонента скорости в течении Куэтта

## Явная схема интегрирования уравнения переноса:

$$1. \text{ADV}^n = -\Delta t \left[ \frac{\partial u_i C}{\partial x_i} \right]_h^n,$$

$$2. \text{DIFF}^n = \Delta t \left[ \frac{1}{Re \cdot Sc} \frac{\partial^2 C}{\partial x_i \partial x_i} \right]_h^n,$$

$$3. \text{RHS}^n = \frac{3}{2} (\text{ADV} + \text{DIFF})^n - \frac{1}{2} (\text{ADV} + \text{DIFF})^{n-1} - [\Delta t \cdot T^{-1} C]_h^n,$$

Схемы 2-ого и 4-ого  
порядка точности

Компенсационное суммирование  
Кэхэна

$$\rightarrow 4. C^{n+1} = C^n + \text{RHS}^n$$

Все данные и вся арифметика в половинной точности

## Реализация в половинной точности

Для использования половинной точности ( FP16 ) необходимо учитывать следующие вещи:

- для реализации арифметических операций надо использовать специальные функции, которые, например, представлены в CUDA

```
__device__ __half __hadd ( const __half a , const __half b )  
    Performs half addition in round-to-nearest-even mode.  
  
__device__ __half __hsub ( const __half a , const __half b )  
    Performs half subtraction in round-to-nearest-even mode.
```

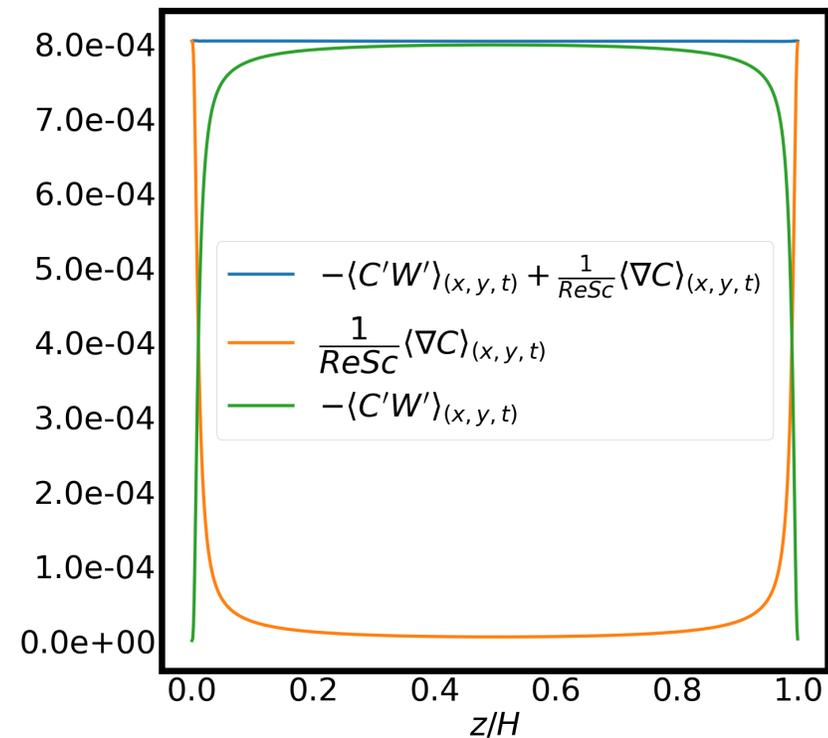
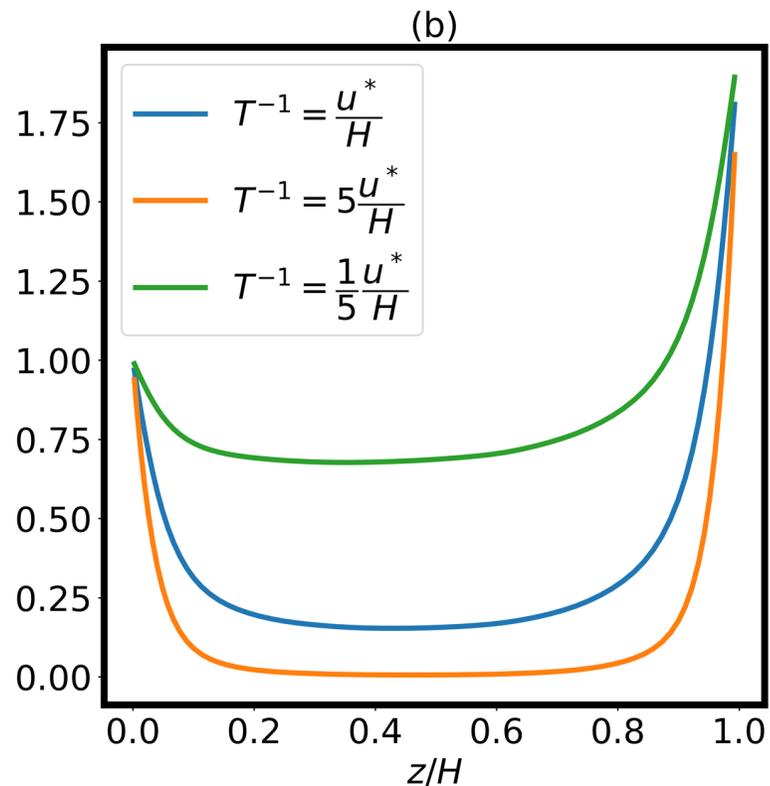
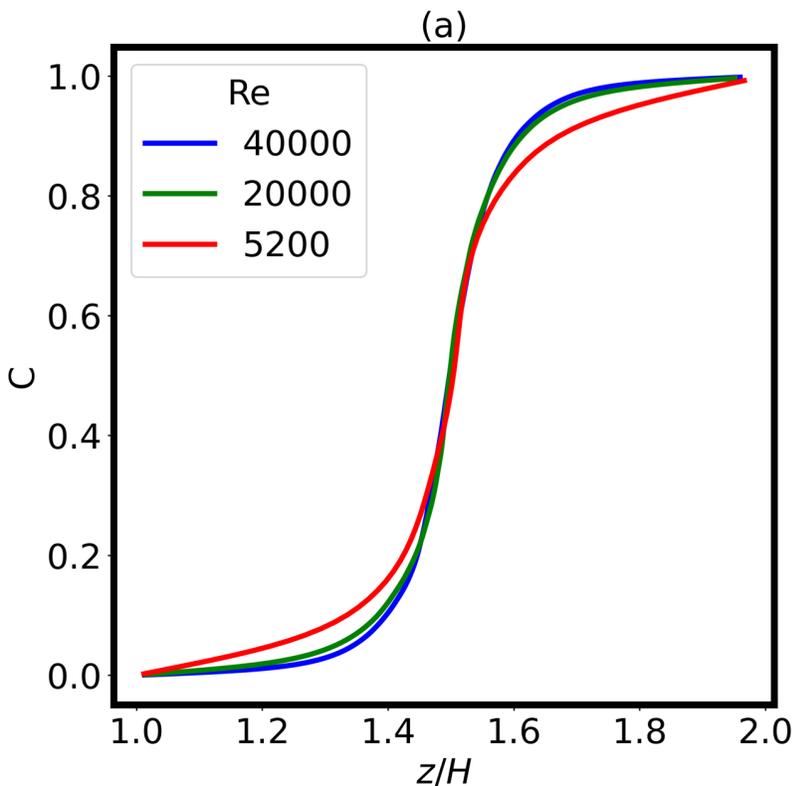
- максимальное по модулю представимое число в FP16 есть 65504, минимальное (субнормальное) положительное значение  $\approx 5.96 \times 10^{-8}$  → возможное решение — нормировка используемых констант, смена порядка арифметических операций

$$ADV^n = -\Delta t \left[ \frac{\partial u_i C}{\partial x_i} \right]_h^n - \text{расчет адвекции}$$

$$4. C^{n+1} = C^n + \text{RHS}^n$$

- при реализации в FP16 возможно возникновение стагнации → возможное решение — использование компенсационных алгоритмов

# Численные результаты



**Рис.** Средний профиль примеси (a) и средний профиль примеси при разном времени экспоненциального затухания концентрации (b) в FP16 и в FP32 (порядок нормы ошибки не превышает 0.01%)

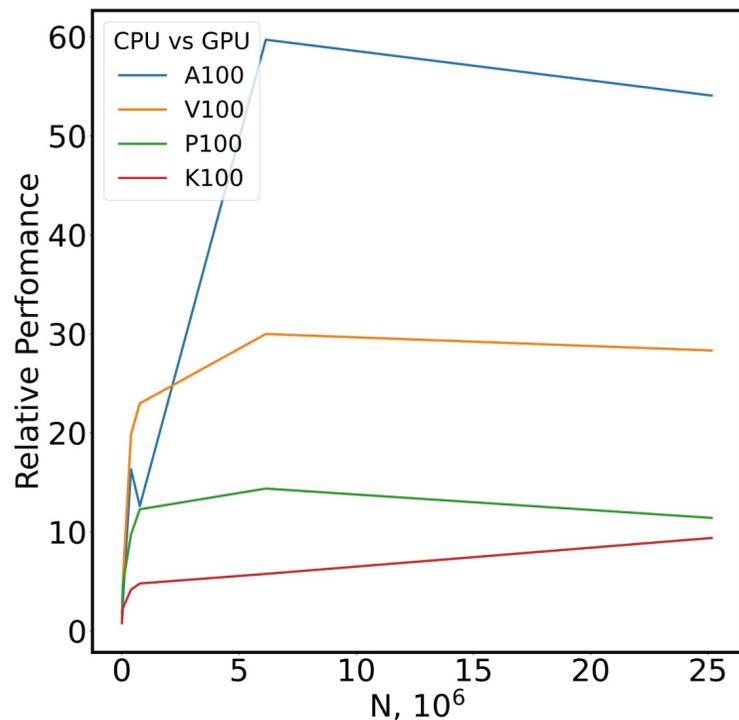
**Рис.** Средний полный поток скаляра и его компоненты: турбулентная и вязкая часть (Re = 40000)

$$\frac{\|res_{fp32} - res_{fp16}\|_{L_2}}{\|res_{fp32}\|_{L_2}} \cdot 100, \|x = (x_1, \dots, x_n)^T\|_{L_2} = \sqrt{x_1^2 + \dots + x_n^2}$$

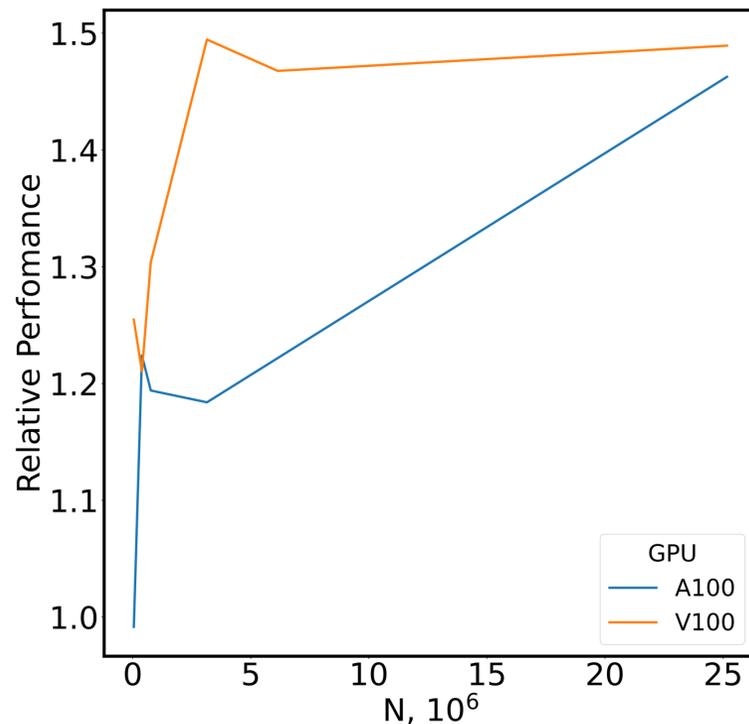
— норма ошибки

*Выполняется также для первых, вторых и третьих статистических моментов*

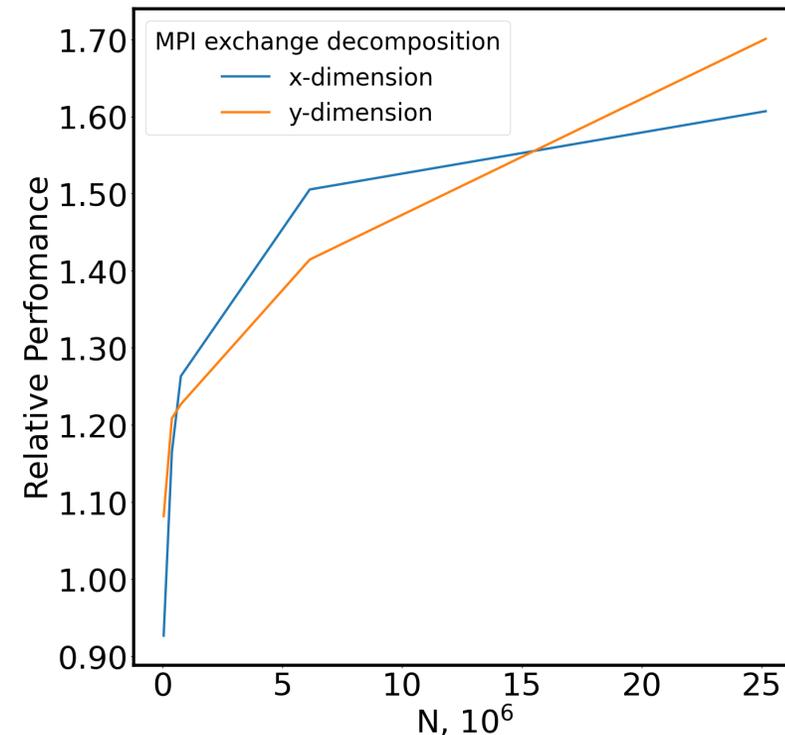
# Результаты оценки производительности



**Рис.** Ускорение моделирования переноса пассивной примеси на GPU к CPU в FP32 в зависимости от размера сетки (N).



**Рис.** Ускорение моделирования переноса пассивной примеси на GPU в FP16 к FP32 в зависимости от размера сетки (N).



**Рис.** Ускорение MPI - обменов массива скаляра в FP16 к FP32 в зависимости от размера сетки (N).

Для выполнения расчетов были использованы вычислительные ресурсы СКЦ МГУ, ЦКП «Центр данных ДВО РАН»

### IPC (Inter-Process Communications)

Обмен между графическими процессорами, находящимися на одном узле

# Обмен данными напрямую между GPU. Результаты оценки производительности

### NCCL

Обмен между графическими процессорами, находящимися на разных узлах

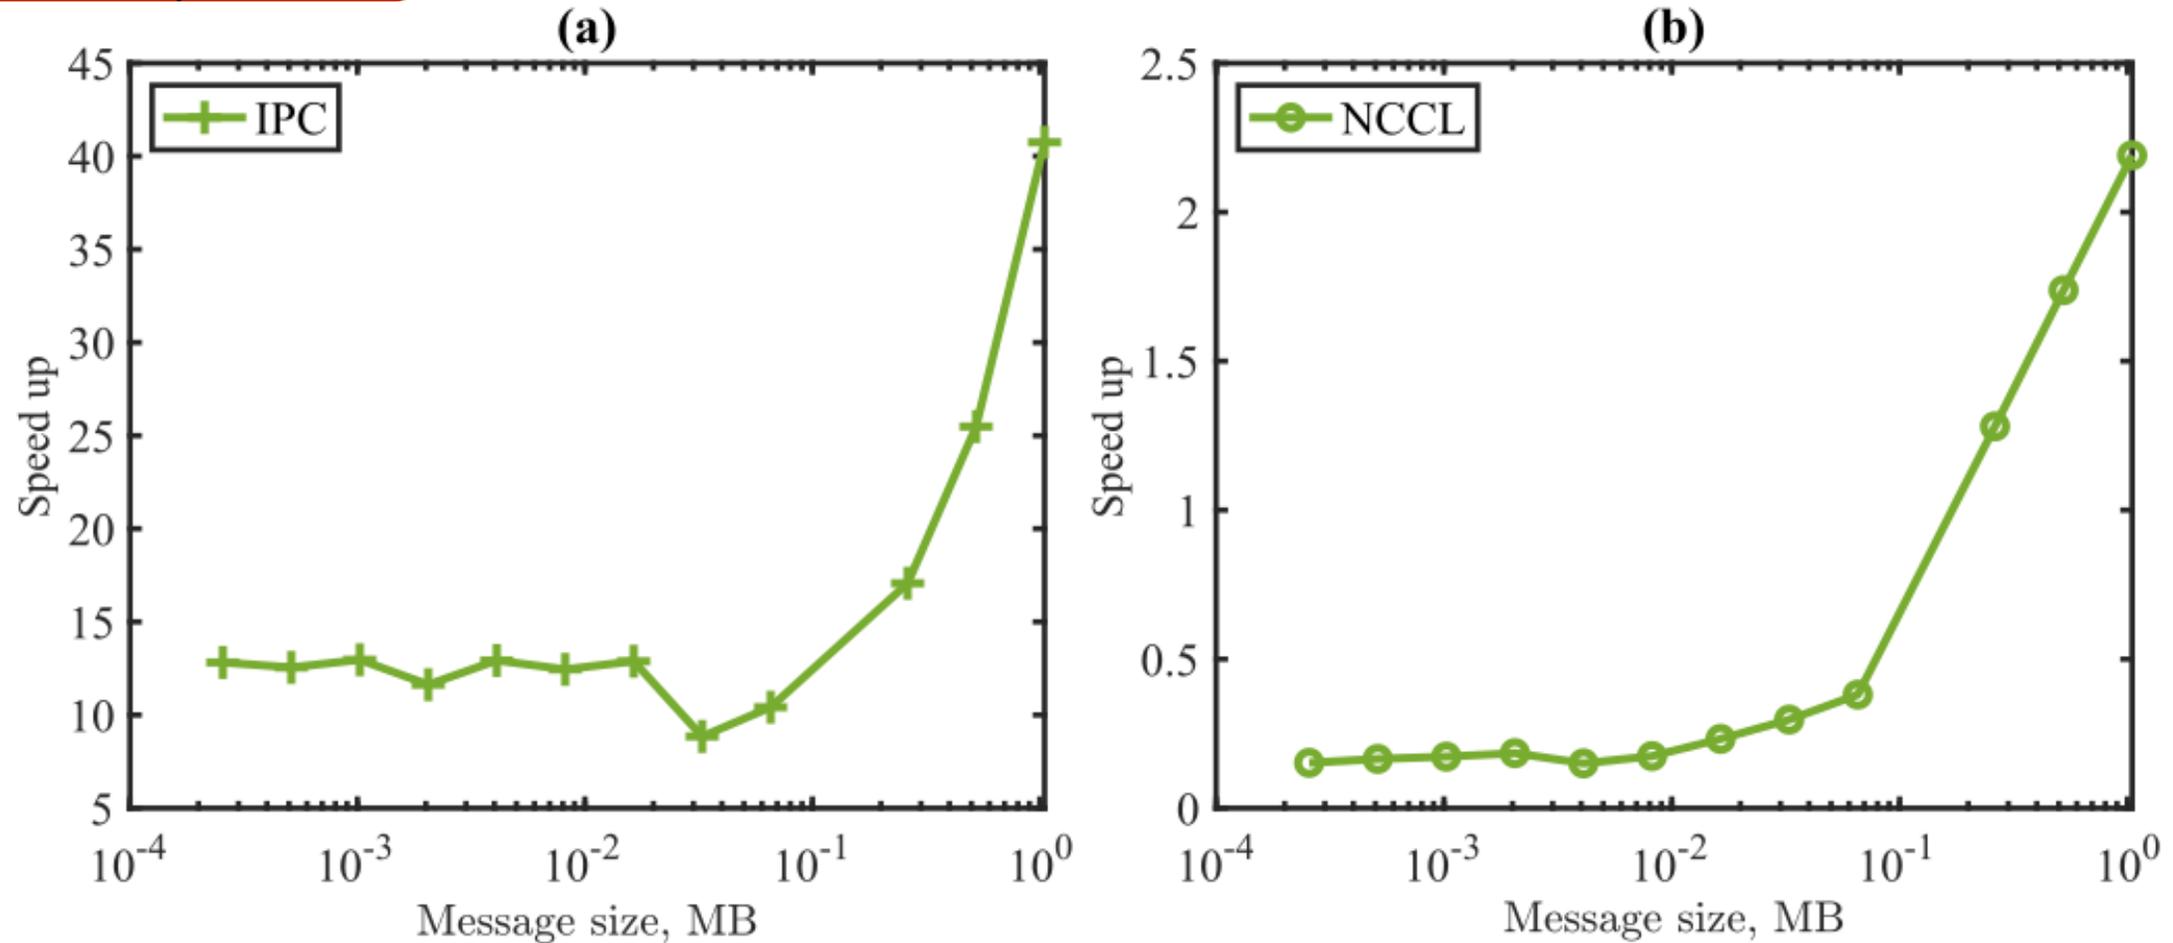


Рис. Ускорение реализации обмена с применением IPC (a) и NCCL (b) на V100 GPU в зависимости от размера пересылаемого сообщения.

# Выводы

## Ускорение переноса примеси в модели океана:

- Использование **shared memory** для реализации схем адвекции не дает значительного ускорения, а результаты применения **kernel fusion** показывают, что данный метод не всегда позволяет достичь ускорения расчетов
- **Прямой подход** техники **scalar fusion** **повысил эффективность** реализации **во всех** проведенных **тестах**, для двумерной модели метод обеспечил **ускорение** примерно в **5** раз на V100 и примерно в **9** раз на A100 **на самой грубой сетке**. **Scalar fusion** с переупорядочиванием обеспечил **увеличение скорости вычислений** примерно в **1.5** раза на V100 по сравнению с прямым методом для двумерного случая при проведении экспериментов на **точных сетках** для схем **DIV** и **UW3**.

## Ускорение за счет FP16:

- Полная реализация блока переноса примеси в **FP16** с использованием алгоритма Кэхэна дает **достаточно точные** численные результаты
- **Ускорение** вычислений GPU - реализации в **FP16** до **1.5** раз в сравнении с исполнением в FP32
- **Уменьшение используемой памяти** в **1.5** раза в сравнении с FP32 с учетом дополнительной памяти для хранения ошибки округления в алгоритме Кэхэна
- **Ускорение** вплоть до **1.6** раз исполнения **MPI-обменов** за счет уменьшения объема передаваемых данных

Ускорение обмена между GPU: использование **IPC ускоряет обмен во всех экспериментах (максимальное ускорение  $\approx 40$  раз для сообщений размером 1МБ)**. Применение **NCCL** позволяет получить **выигрыш в скорости** проведения обмена только в случае **сообщений размером более 0.26МБ (максимальное ускорение  $\approx 2.5$  раза для сообщений размером 1МБ)**

**Спасибо за внимание!**

