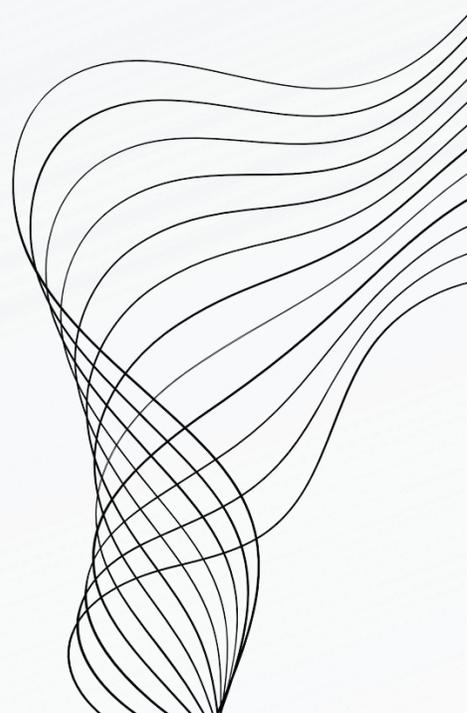
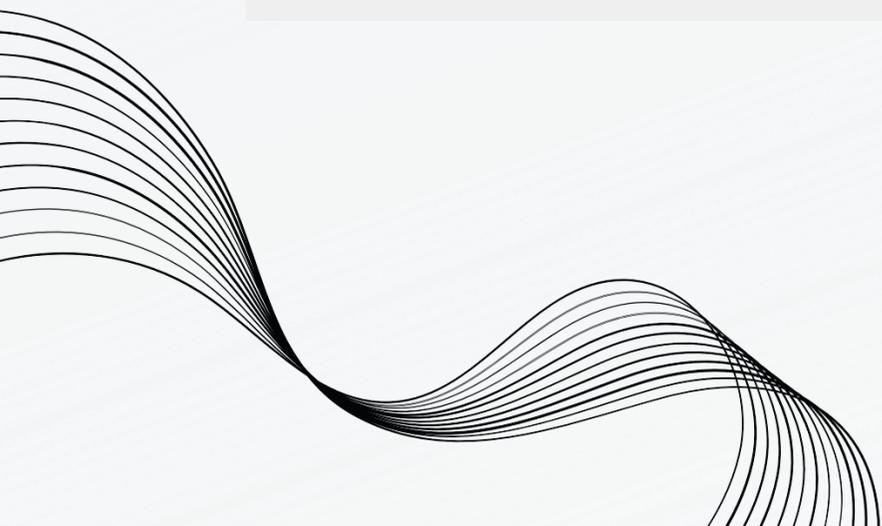


**ПАРАЛЛЕЛЬНЫЙ
АЛГОРИТМ
УМНОЖЕНИЯ
ТРАНСПОНИРОВАННОЙ
МАТРИЦЫ НА ВЕКТОР**



ВВЕДЕНИЕ

Умножение матрицы на вектор — одна из ключевых операций в линейной алгебре, которая встречается в различных областях, таких как численные методы, машинное обучение, компьютерная графика и т.д. В условиях больших матриц и векторов эта операция становится вычислительно затратной, особенно когда требуется трансформация матрицы, например, её транспонирование. Для оптимизации этой задачи применяются параллельные вычисления, которые позволяют разделить работу между несколькими процессами и тем самым ускорить выполнение алгоритма.



1. ПОСТАНОВКА ЗАДАЧИ

- Задача состоит в вычислении произведения транспонированной матрицы A^T на вектор x . То есть:

$$b = A^T \cdot x$$

- A — исходная матрица размером $N \times M$,
- x — вектор размером M ,
- b — результирующий вектор размером N .

3. ТЕОРЕТИЧЕСКАЯ ОСНОВА ПАРАЛЛЕЛЬНОГО УМНОЖЕНИЯ ТРАНСПОНИРОВАННОЙ МАТРИЦЫ НА ВЕКТОР

Разделение матрицы и вектора

Для распределения данных между процессами:

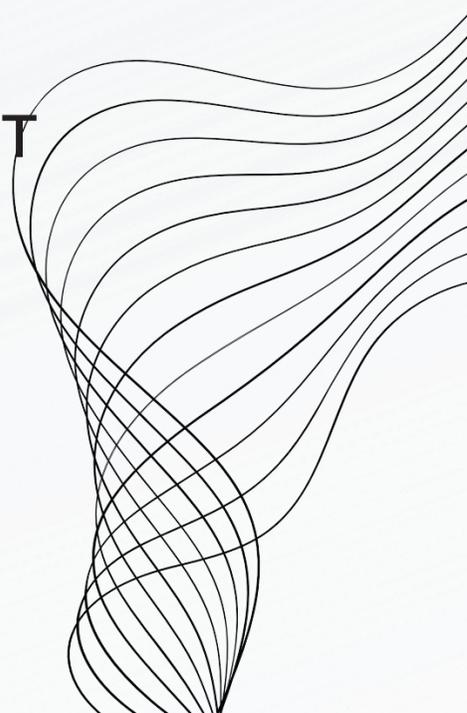
1. Транспонированная матрица делится на блоки строк. Каждый процесс получит одну или несколько строк матрицы для обработки.
2. Вектор x рассылается каждому процессу, так как каждая часть строки транспонированной матрицы должна быть умножена на весь вектор x .



Каждый процесс:

- 1.Получает свою часть матрицы A^T и вектор x .
- 2.Выполняет частичное умножение: для каждого элемента результирующего вектора b , процесс вычисляет скалярное произведение своей части строки матрицы на вектор x .

После вычисления частичных результатов, они отправляются на корневой процесс (или остаются на каждом процессе), где они суммируются с помощью функции `MPI Reduce`, которая суммирует результаты и собирает их в один конечный вектор bbb



Так как массив A уже разбит на блоки, разобъём вектор на блоки, согласованно с разбиением матрицы. Далее на каждом процессе будет происходить умножение частей матриц на части вектора. Полученные вектора с разных процессов нужно будет сложить. Схему этой операции можно увидеть на следующем рисунке

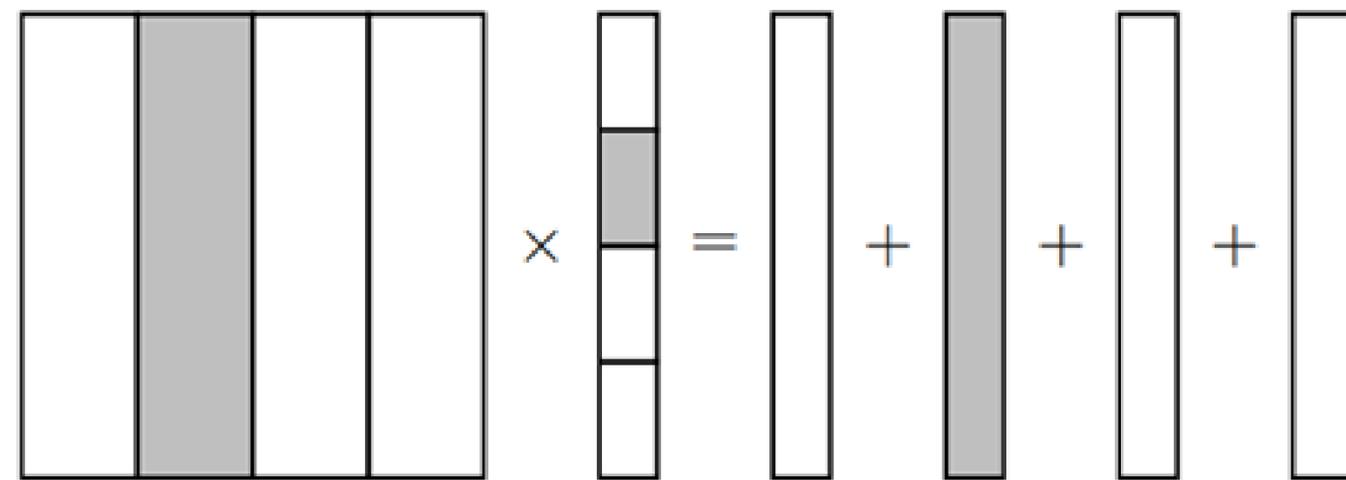


Рис. 2.2: Схема умножения транспонированной матрицы на вектор

ПАРАЛЛЕЛЬНАЯ РЕАЛИЗАЦИЯ УМНОЖЕНИЯ ТРАНСПОНИРОВАННОЙ МАТРИЦЫ НА ВЕКТОР

```
from mpi4py import MPI
from numpy import empty, array, int32, float64, dot

comm = MPI.COMM_WORLD
rank = comm.Get_rank()
numprocs = comm.Get_size()
```

```
# Размеры матрицы
N = 3 # Число строк матрицы A
M = 4 # Число столбцов матрицы A (равно размеру вектора x)

# Матрица и вектор на процессе с рангом 0
if rank == 0:
    A = array([[1.0, 2.0, 3.0, 4.0],
              [5.0, 6.0, 7.0, 8.0],
              [9.0, 10.0, 11.0, 12.0]], dtype=float64)
    x = array([1.0, 2.0, 3.0, 4.0], dtype=float64)
else:
    A = None
    x = None
```

В этом коде мы импортируем библиотеки `mpi4py` для параллельных вычислений с использованием MPI и `numpy` для работы с матрицами и векторами, создаем объект `comm`, представляющий группу процессов, участвующих в вычислениях, где каждый процесс имеет уникальный идентификатор `rank`, а `numprocs` указывает общее количество процессов, запущенных для выполнения программы.

Здесь мы определяем размеры матрицы `A` и вектора `x`. `N` — количество строк матрицы `A` (3). `M` — количество столбцов матрицы `A` (4), и также это размер вектора `x`. Только процесс с рангом 0 (корневой процесс) инициализирует полную матрицу `A` и вектор `x`. Остальные процессы пока не имеют данных (`A = None`, `x = None`).

РАЗДЕЛЕНИЕ МАТРИЦЫ И ВЕКТОРА МЕЖДУ ПРОЦЕССАМИ

- Здесь происходит подготовка к распределению данных между процессами.
- `rcounts` хранит количество строк, которые будут переданы каждому процессу.
- `displs` хранит смещения (индексы начала строк), откуда каждый процесс должен начинать чтение.
- В корневом процессе (`rank == 0`) мы определяем, сколько строк должно быть передано каждому процессу.
- `ave` — это среднее количество строк, которые получает каждый процесс.
- `res` — остаток, который мы добавляем к распределению строк для равномерного разделения данных.
- Затем цикл распределяет строки между процессами с рангами от 1 до `numprocs-1`. Корневой процесс с `rank=0` не участвует в вычислениях.

```
# Распределение данных между процессами
rcounts = empty(numprocs, dtype=int32) #
Количество строк для каждого процесса
displs = empty(numprocs, dtype=int32) # Индексы
смещений для каждого процесса

if rank == 0:
    ave, res = divmod(M, numprocs - 1)
    rcounts[0] = 0
    displs[0] = 0
    for k in range(1, numprocs):
        rcounts[k] = ave + 1 if k <= res else ave
        displs[k] = displs[k - 1] + rcounts[k - 1]
```

РАССЫЛКА ВЕКТОРА И ДАННЫХ МАТРИЦЫ

```
# Рассылка вектора x всем процессам
x_part = empty(M, dtype=float64)
comm.Bcast([x, MPI.DOUBLE], root=0)

# Каждый процесс получает часть матрицы A^T
A_part = empty((M, N), dtype=float64)
comm.Scatterv([A, rcounts, displs, MPI.DOUBLE], A_part,
root=0)
```

В этой части происходит распределение данных между процессами.

Вектор x передается каждому процессу с использованием MPI-функции `Bcast` (broadcast). Это важно, так как каждый процесс должен иметь полный вектор для выполнения умножения. Для матрицы используется функция `Scatterv`, которая раздает строки матрицы транспонированного вида (A^T) каждому процессу. Каждый процесс получает только свою часть строк матрицы A^T .

Вычисление частичного результата

```
# Часть вычисления произведения A^T * x
b_temp = dot(A_part.T, x_part)
```

После того как каждый процесс получил свою часть транспонированной матрицы и вектор, происходит вычисление частичного произведения.

Функция `dot()` выполняет операцию умножения каждой строки матрицы A^T на вектор x для получения частичного результата.

Важно: каждый процесс вычисляет только свою часть итогового вектора b .

СБОР РЕЗУЛЬТАТОВ И ВЫВОД ИТОГОВ

```
# Сбор всех частичных результатов на корневом процессе
b = None
if rank == 0:
    b = empty(N, dtype=float64)
comm.Reduce(b_temp, b, op=MPI.SUM, root=0)

# Вывод результата на процессе 0
if rank == 0:
    print("Результат умножения A^T на x:", b)
```

- *Каждый процесс вычисляет свою часть результата в переменной `b_temp`.*
- *С помощью функции `Reduce` все частичные результаты собираются и суммируются на корневом процессе (`rank=0`).*
- *Аргумент `op=MPI.SUM` означает, что результаты будут суммироваться.*
- *Корневой процесс выводит на экран окончательный результат умножения транспонированной матрицы на вектор.*