Параллельная обработка больших графов

Занятие 8

А.С. Семенов

dislab.org

НИЦ ВТ

DISLab

Проблемы и подходы к решению задач обработки графов в рамках одного вычислительного узла

Поиск вширь в графе

```
Q = {v_start}
Visited = {v_start}
while Q ≠ {}
    Q_next = {}
    for all vertex ∈ Q do
        for all w: (vertex, w) ∈ E do
            if w ∉ Visited then
                Q_next = Q_next ∪ w
                Visited = Visited ∪ w
            endif
        end for
    end for
    Q = Q_next
end while
```

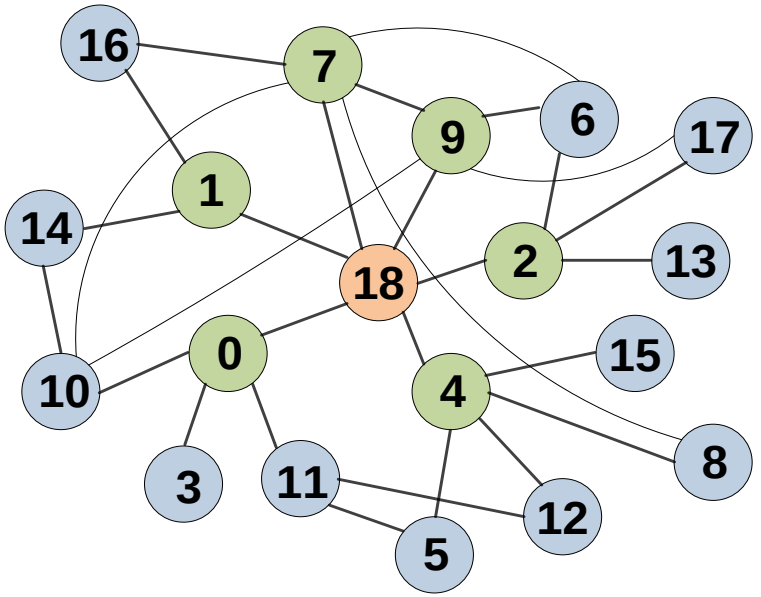

Поиск вширь в графе (BFS)
Подход Queue-based, алгоритм simple

$Q_{counter} = 1$
Q[0] = root
Visited[root] = 1
while $Q_{counter} > 0$
    $Q_{next\_counter} = 0$
    #pragma omp parallel for
    for all vertex ∈ Q **do**
        for all w: (vertex, w) ∈ E **do**
            if Visited[w] == 0 **then**
                Q_{next}[__sync_fetch_and_add($Q_{next\_counter}$, 1)] = w
                Visited[w] = 1
            endif
        end for
    end for
    swap(Q, Q_{next}) // *обмен Q и* Q_{next}
end while

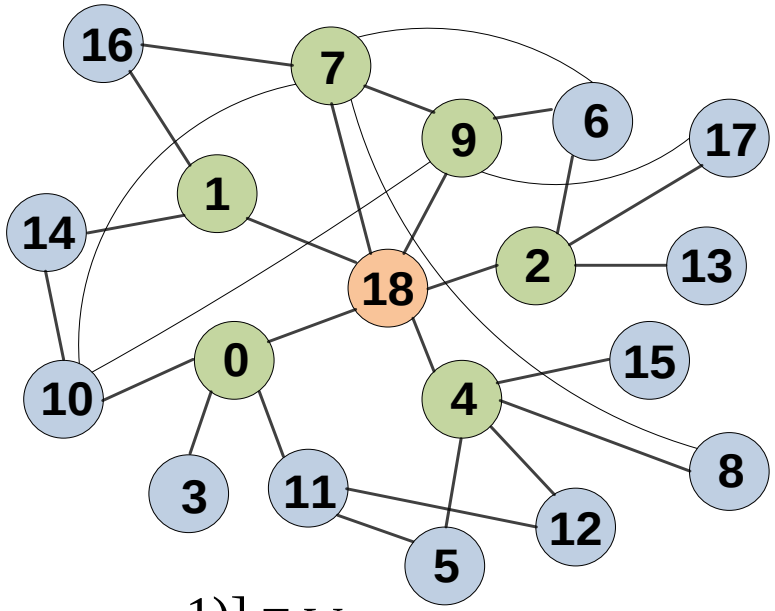

Производительность алгоритма simple в зависимости от числа используемых тредов на сопроцессоре Phi-5110P

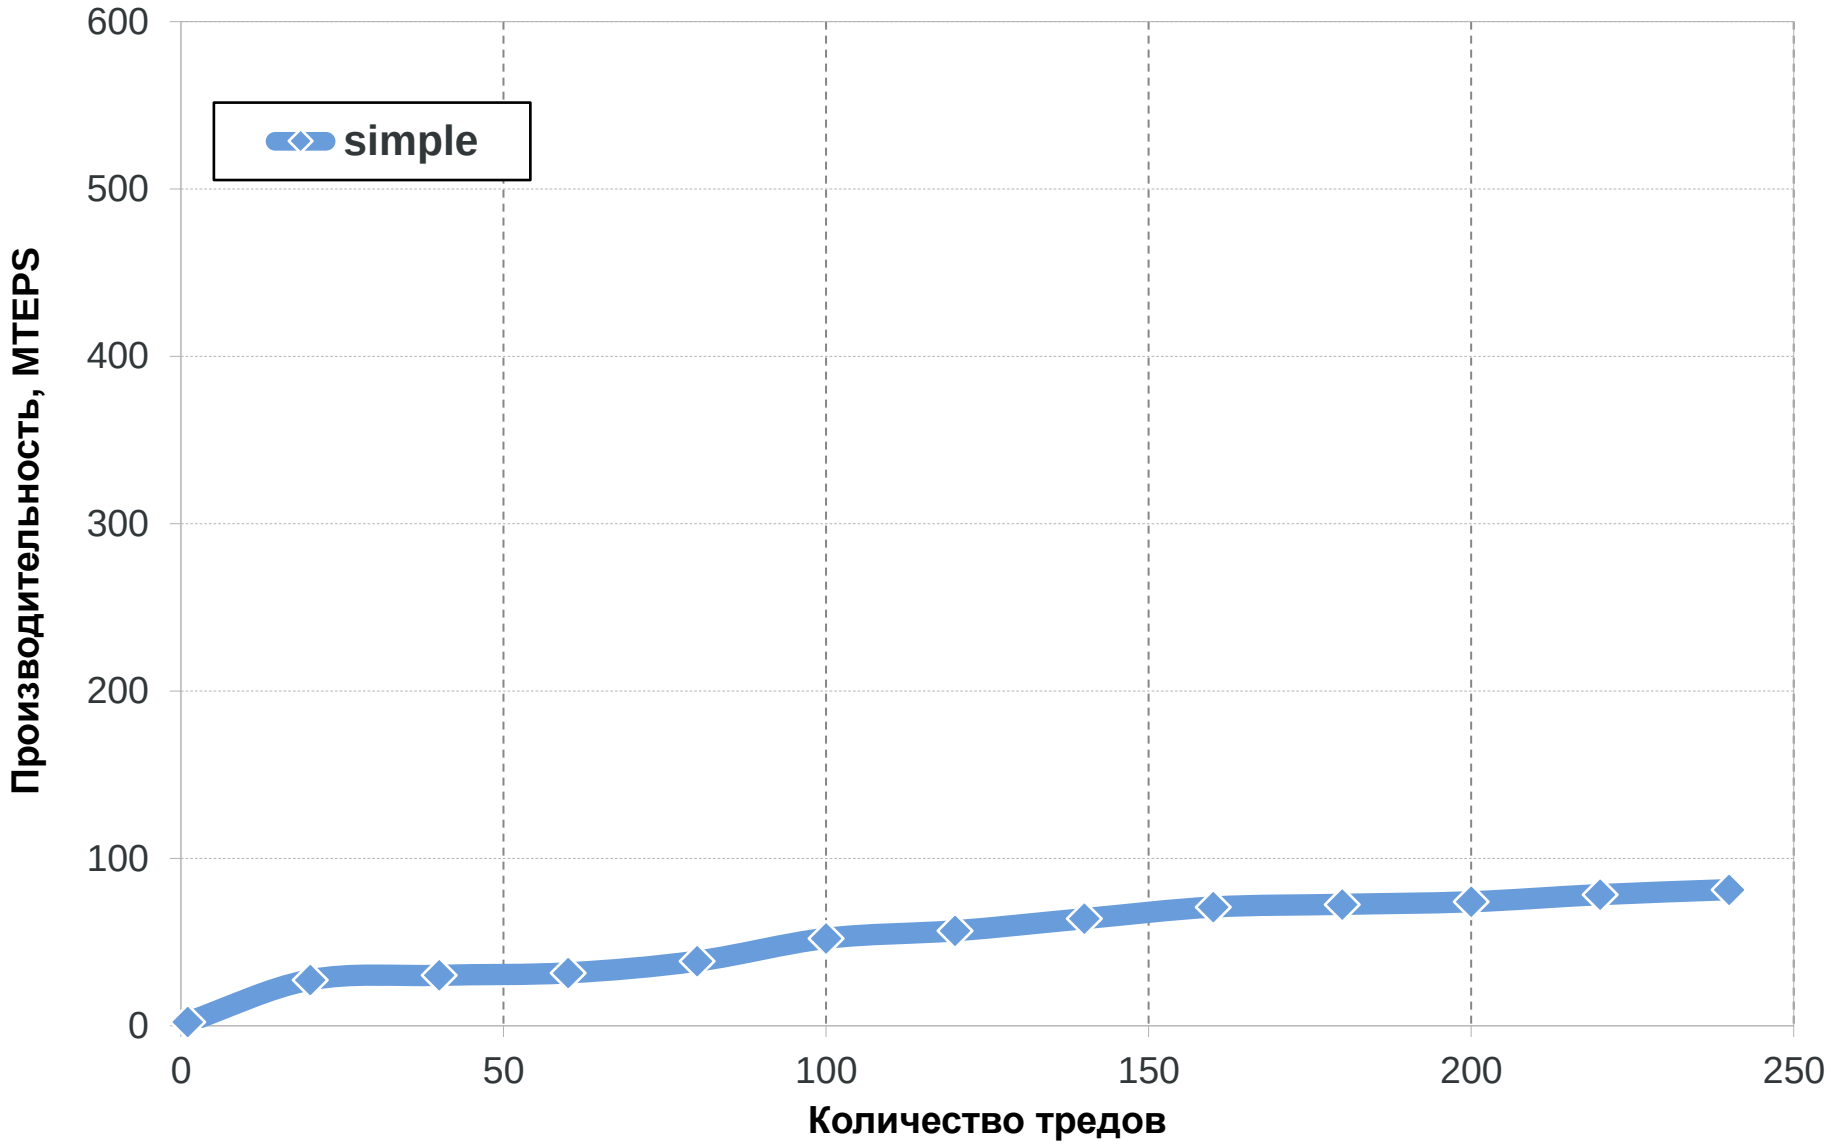

Число вершин в графе: N = 2^{27} (134 млн), средняя связность вершины: k = 8

Производительность алгоритмов simple и block в зависимости от числа используемых тредов на сопроцессоре Phi-5110P

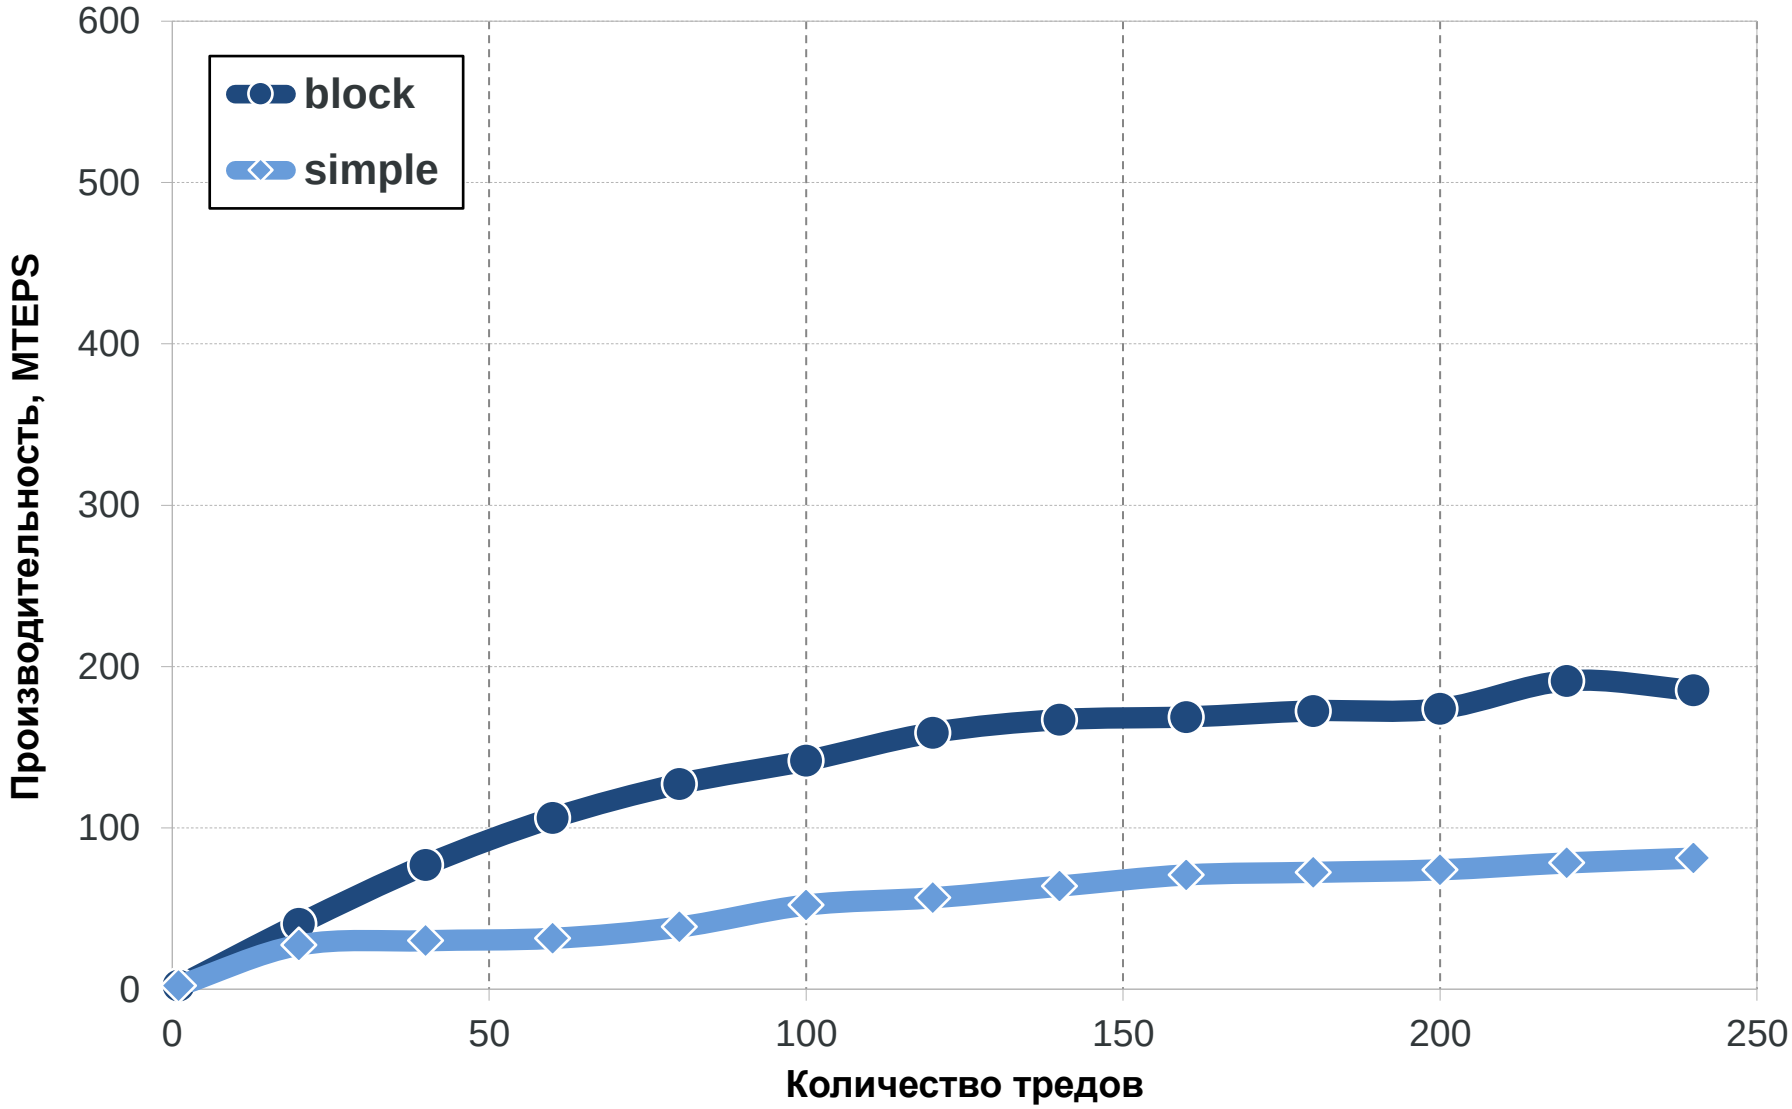

Число вершин в графе: N = 2^{27} (134 млн), средняя связность вершины: k = 8

Недостатки подхода Queue-based

```
#pragma omp parallel for
for all vertex ∈ Q  do
    for all w: (vertex, w) ∈ E  do
        if Visited[w] ==  0 then
            Q_next[__sync_fetch_and_add(Q_next_counter, 1)] = w
            Visited[w] = 1
        endif
    end for
end for
```

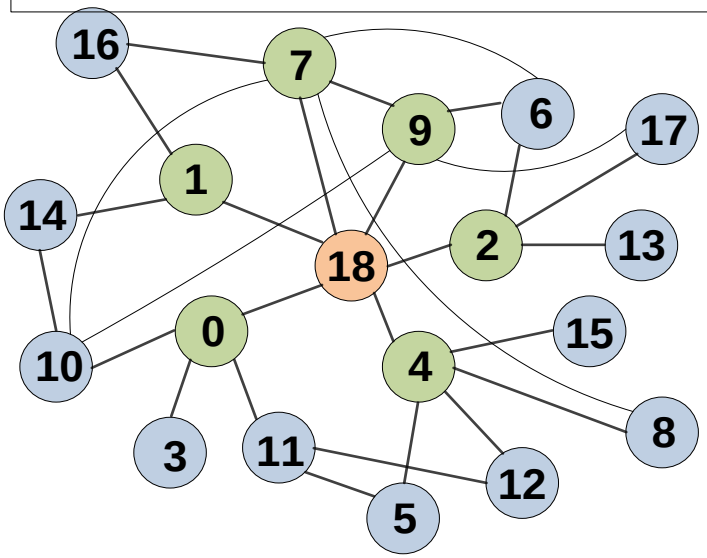

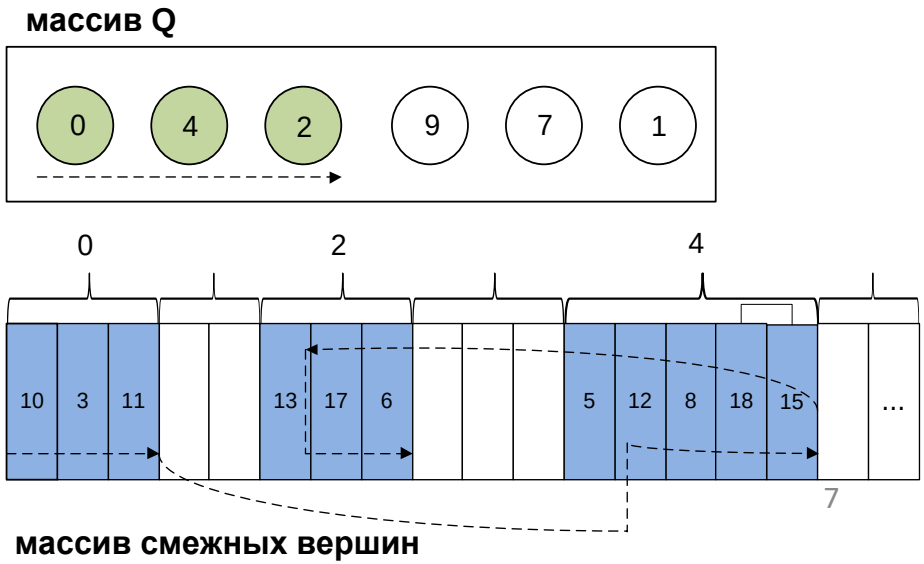

Подход Read-based, алгоритм read

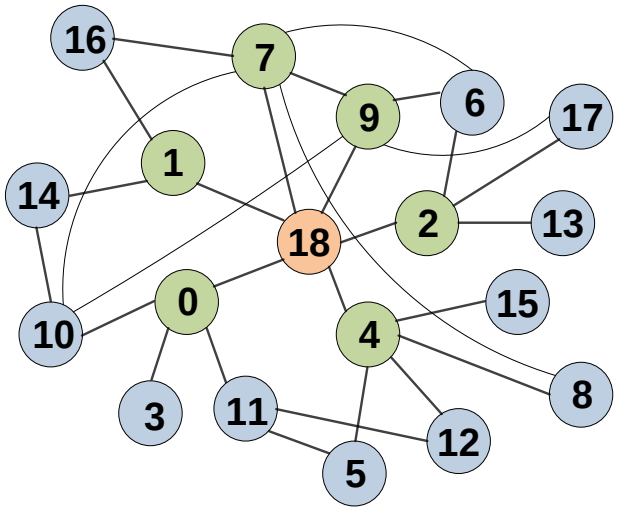


```
#pragma omp parallel for reduction (…)
for all vertex ∈ V do
    if levels[vertex] ≠ numLevel then
     continue
    for all w: (vertex, w) ∈ E  do
        if levels[w] == -1 then
            levels[w] = numLevel + 1
            nLevelVerts =  nLevelVerts + 1
        end if
    end for
end for
```

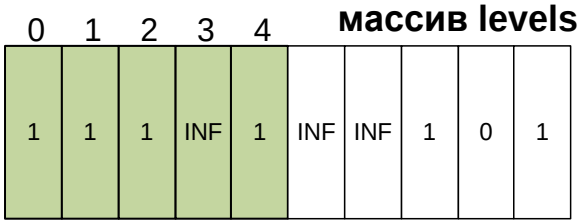

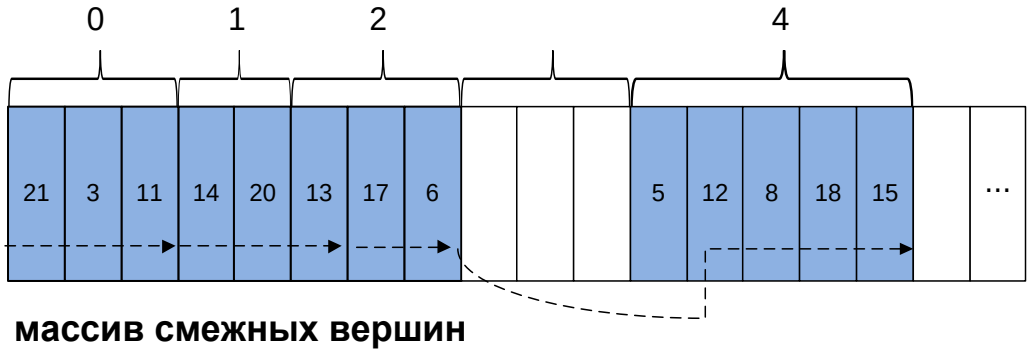

Производительность алгоритмов simple, block и read в зависимости от числа используемых тредов на сопроцессоре Phi-5110P

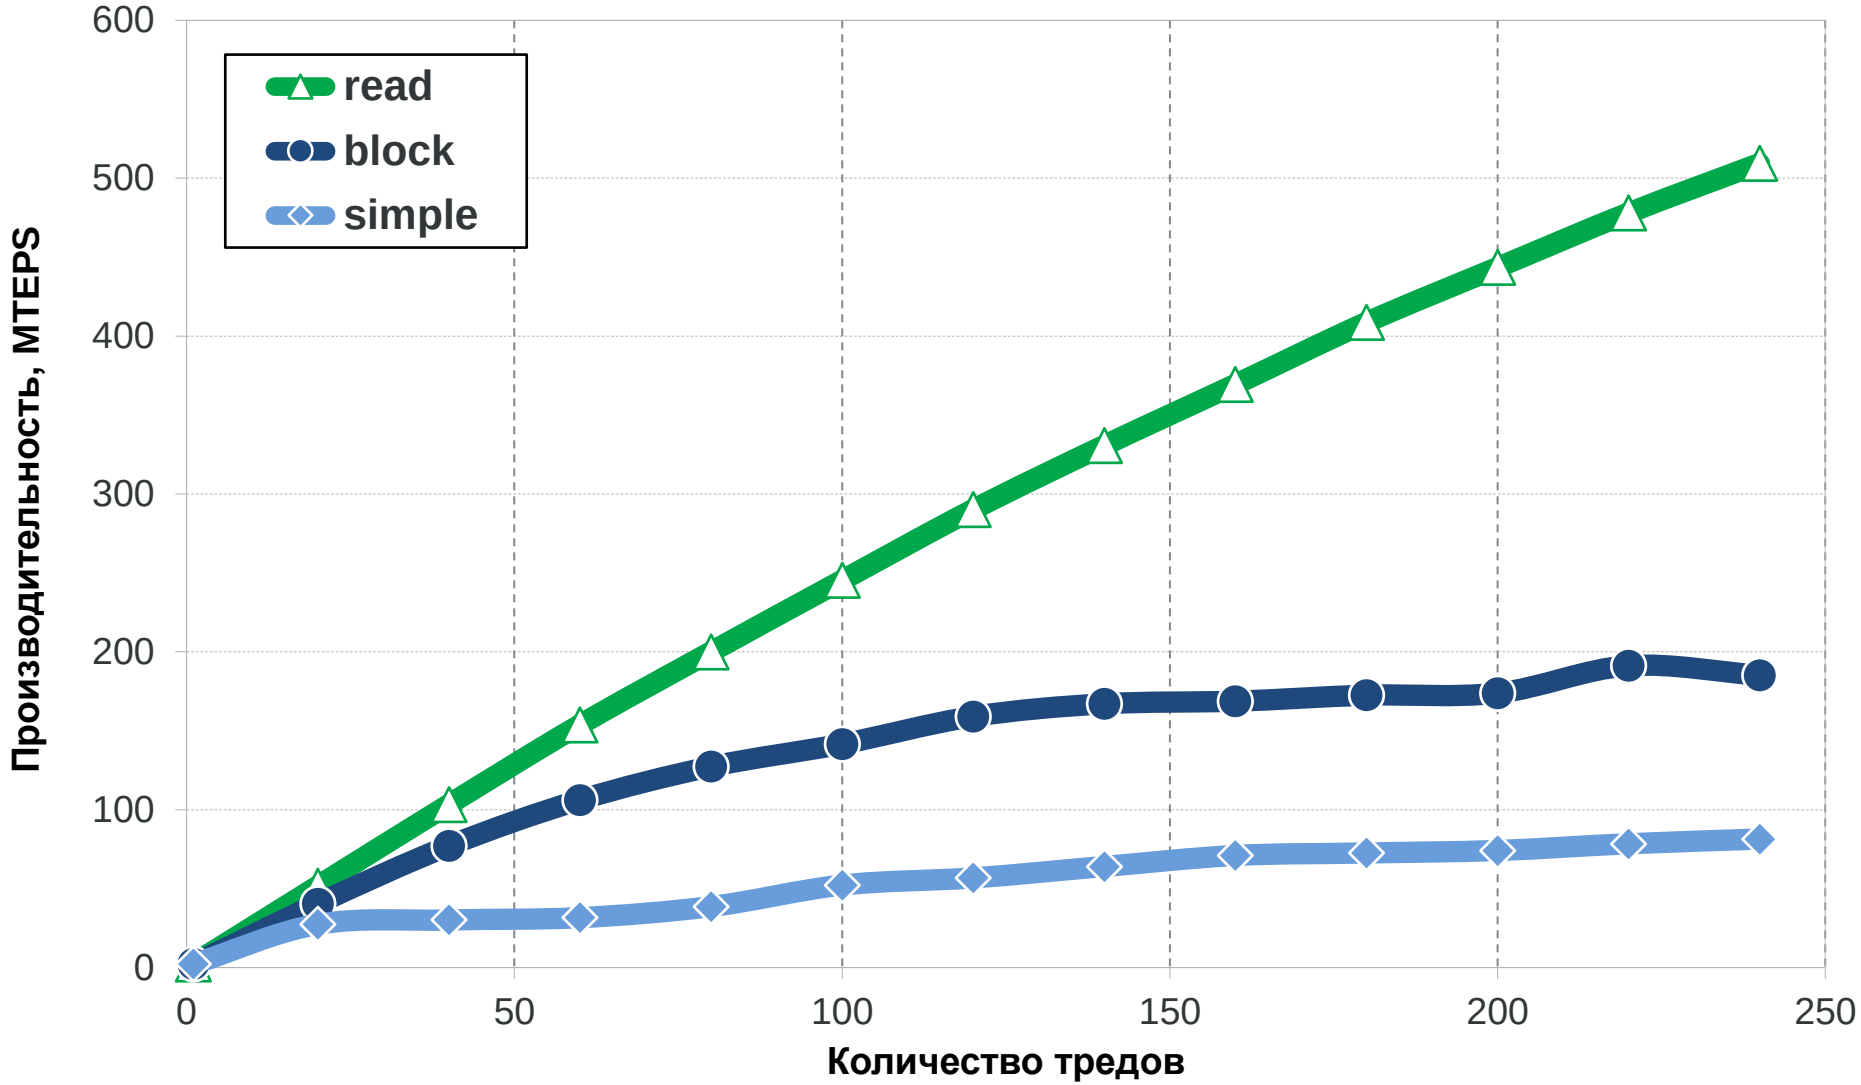

Число вершин в графе: N = 2^{27} (134 млн), средняя связность вершины: k = 8

Алгоритм bottom-up-hybrid

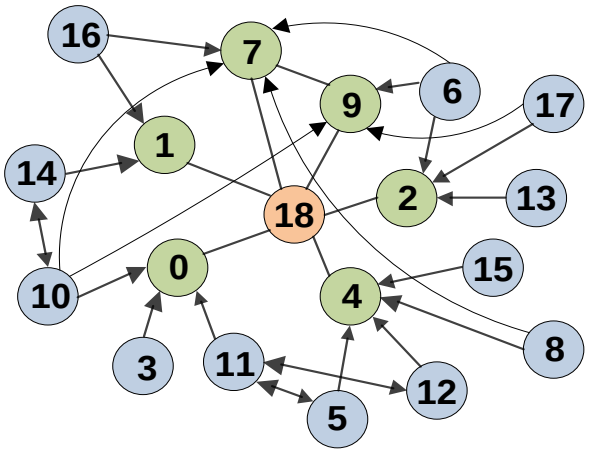


```
#pragma omp parallel for reduction (…)
for all vertex ∈ V do
        if levels[vertex] == -1 then
                for all w: (vertex, w) ∈ E  do
                        if levels[w] == numLevel then
                                levels[vertex] = numLevel + 1
                                nLevelVerts =  nLevelVerts + 1
                                break
                        end if
                end for
        end if
end for
```

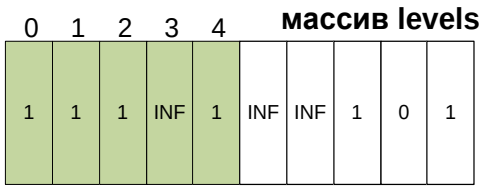

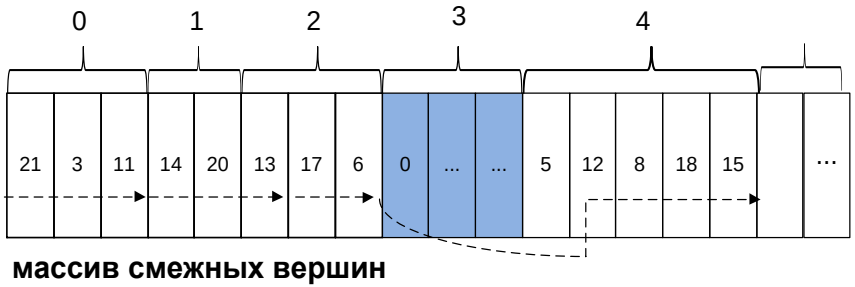

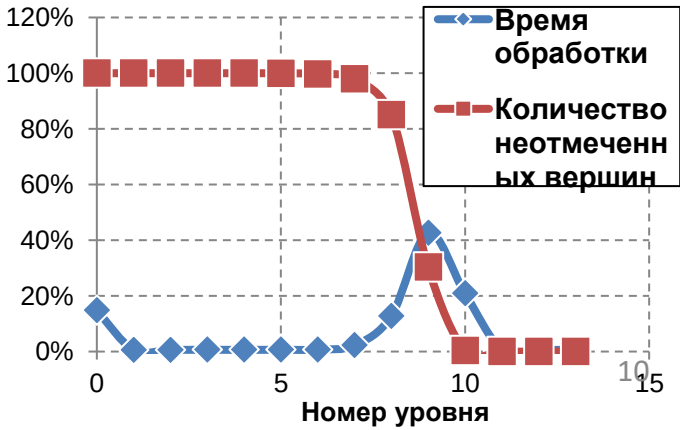

Производительность алгоритмов simple, block, read и bottom-up-hybrid в зависимости от числа используемых тредов на сопроцессоре Phi-5110P

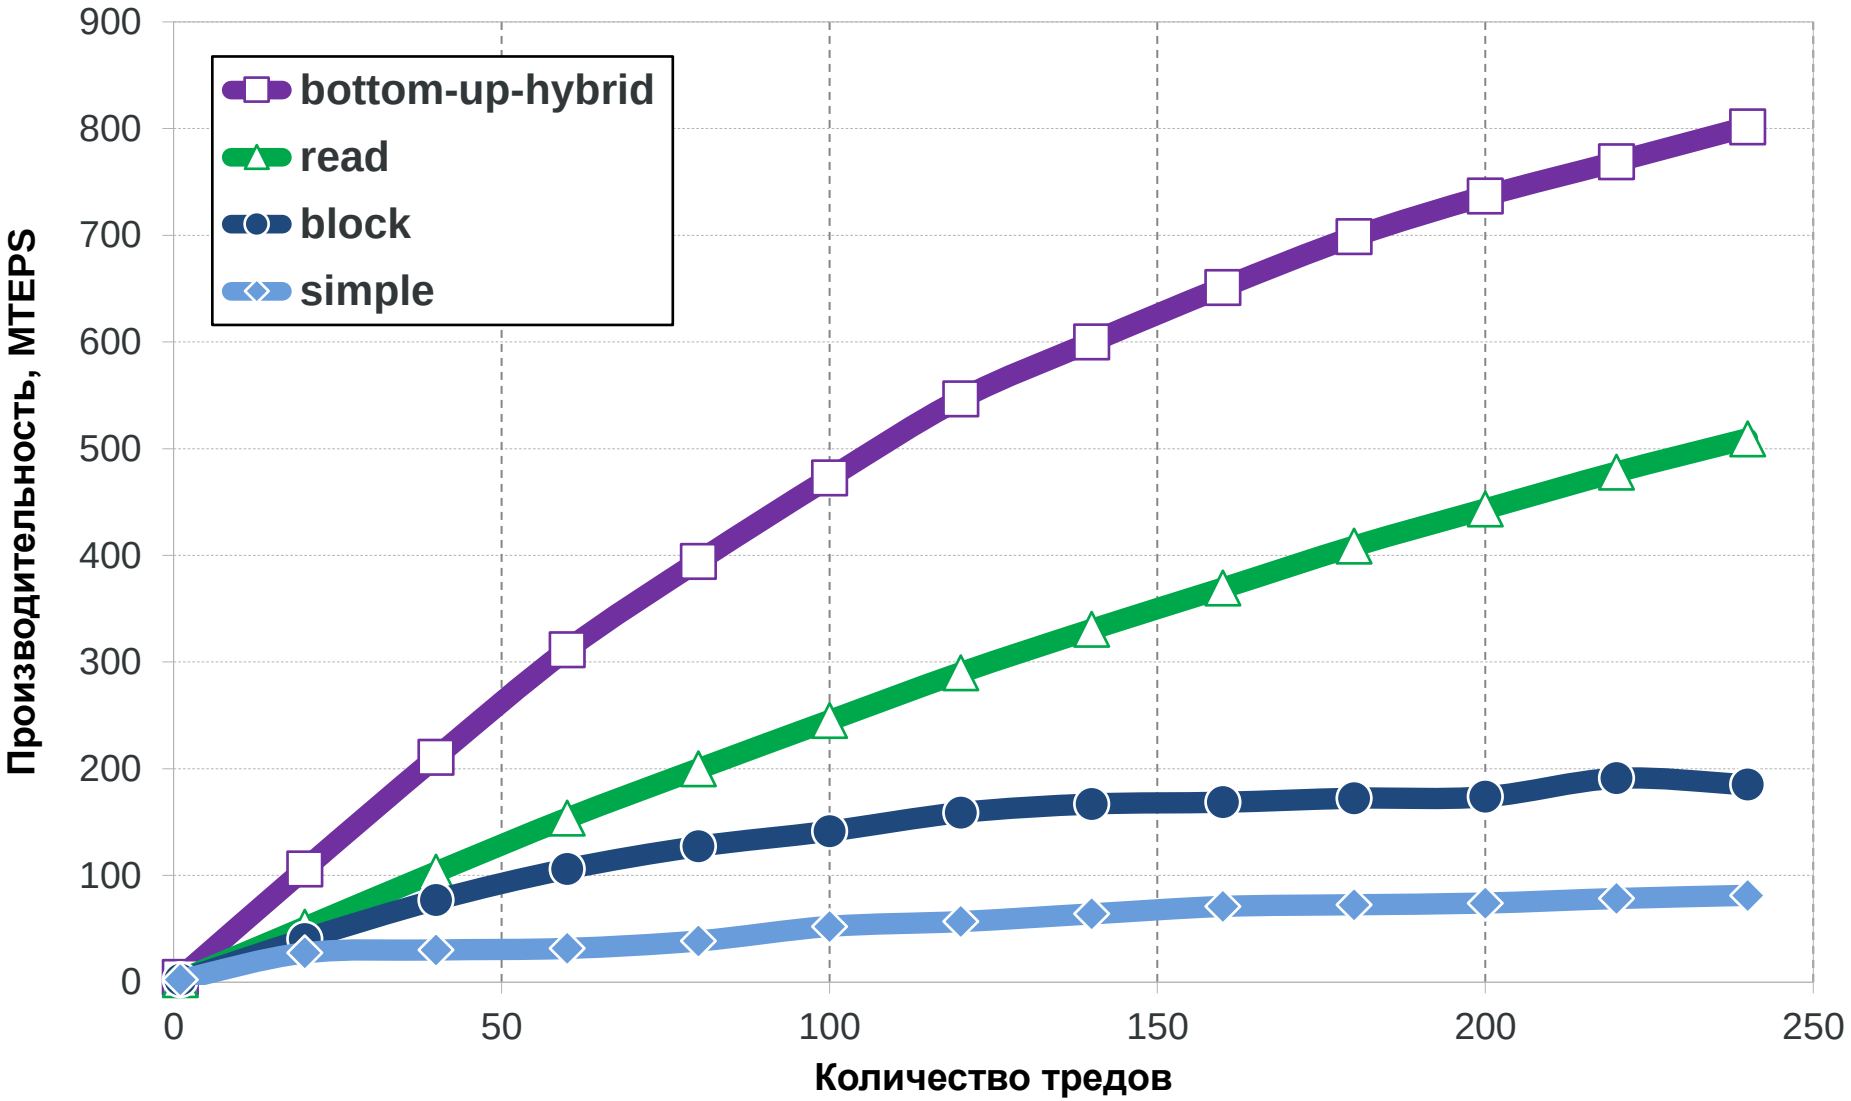

Число вершин в графе: N = 2^{27} (134 млн), средняя связность вершины: k = 8

Недостатки алгоритмов read и bottom-up-hybrid

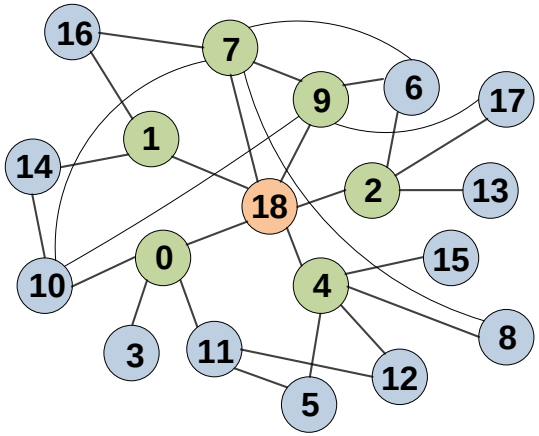


```
#pragma omp parallel for reduction
(…)
for all vertex ∈ V do
    if levels[vertex] ≠ numLevel then
        continue
    for all w: (vertex, w) ∈ E  do
        if levels[w] == -1 then
            levels[w] = numLevel + 1
        …
        end if
    end for
end for
```

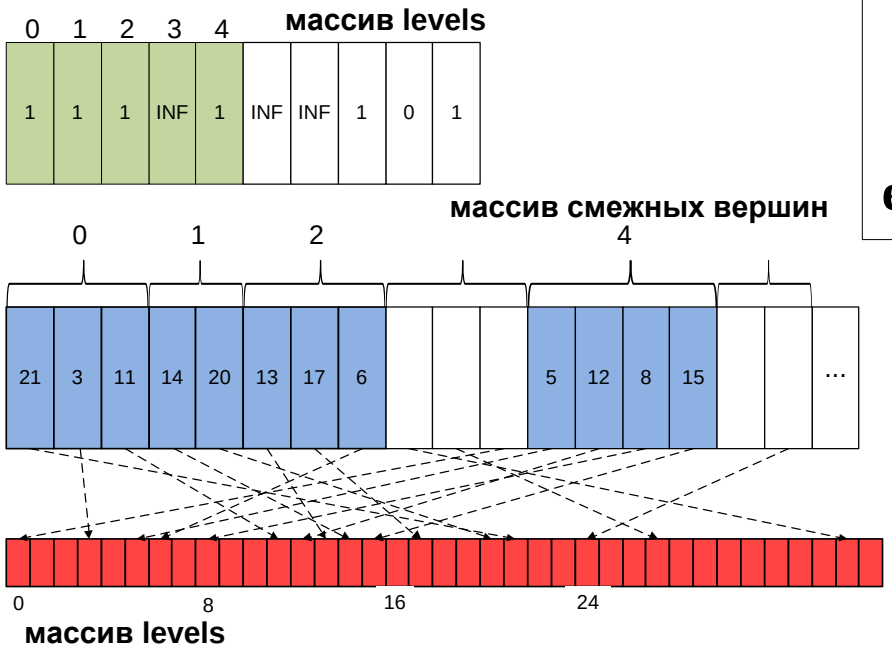

	SB	Phi-5110P
Частота, ГГц	2.2	1.05
Задержка обращения в память (такты)	~150	~300

Решение: ручная развертка цикла + использование prefetch

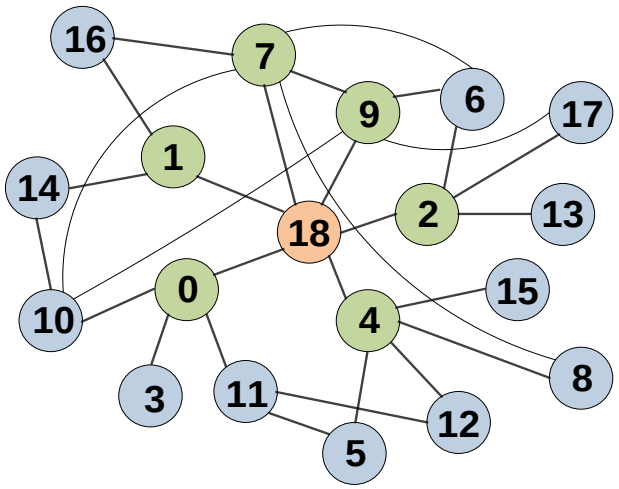

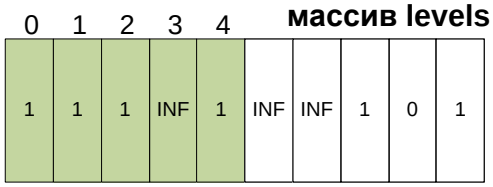

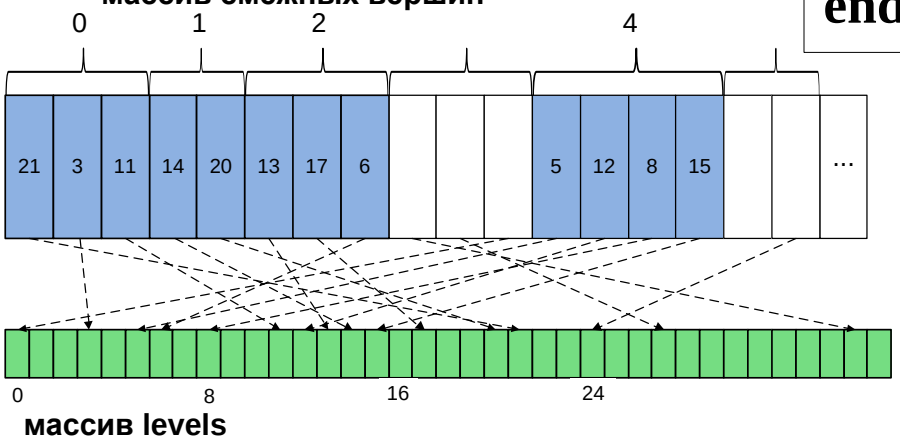


```
#pragma omp parallel for reduction (…)
for all vertex ∈ V do
    if levels[vertex] ≠ numLevel then continue
    for all w: (vertex, w) ∈ E  do
        prefetch(levels[w])
        …
        if levels[w] == -1 then
            levels[w] = numLevel + 1
        …
        end if
    end for
end for
```

	SB	Phi-5110P
Пиковая ПС памяти, ГБ/с	51	352
ПС чтения из памяти, ГБ/с; Последовательный / случайный доступ	42 / 3.3	183 / 3.8
Задержка, тактов	200	300

Память SDRAM

- Память организована как матрица

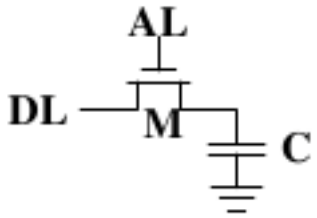

- На все операции требуется энергия и время
- Чтение
  - Усилитель считывания
  - Перезарядка после чтения (энергия и время)
- Перезарядка памяти

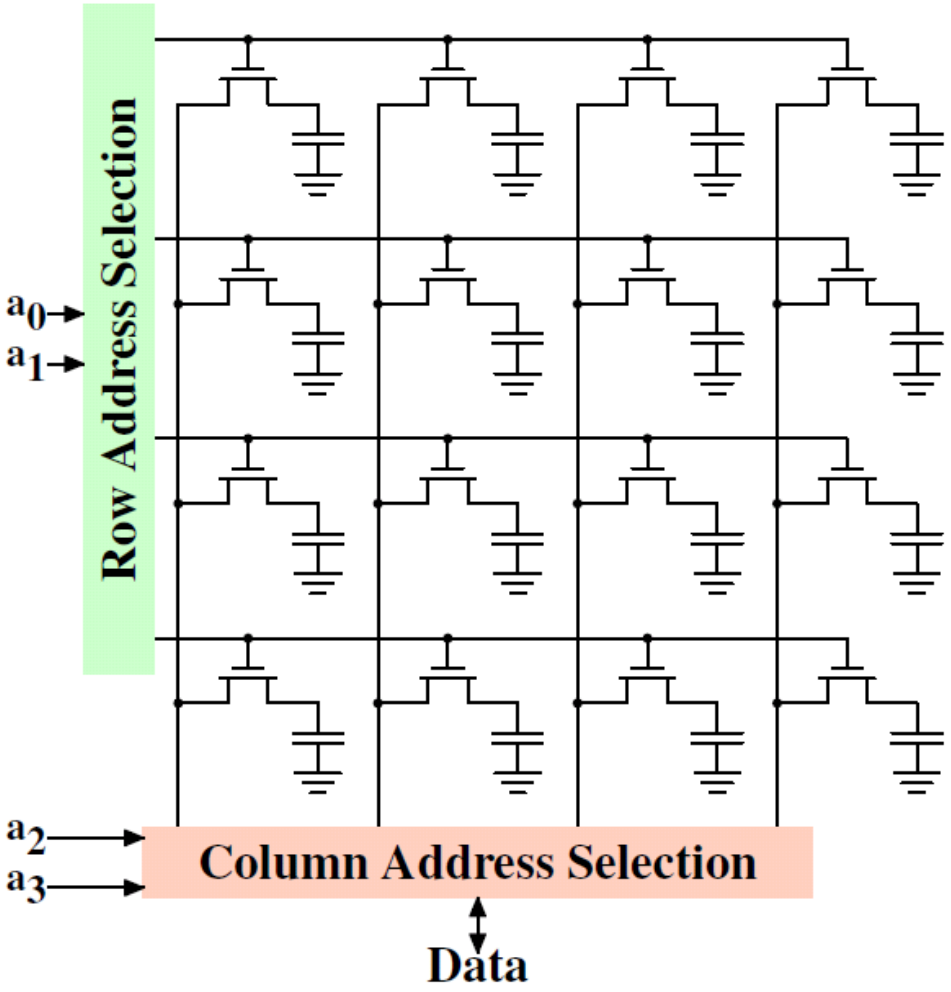

Память SDRAM

- На определение состояния и перезарядку требуется время

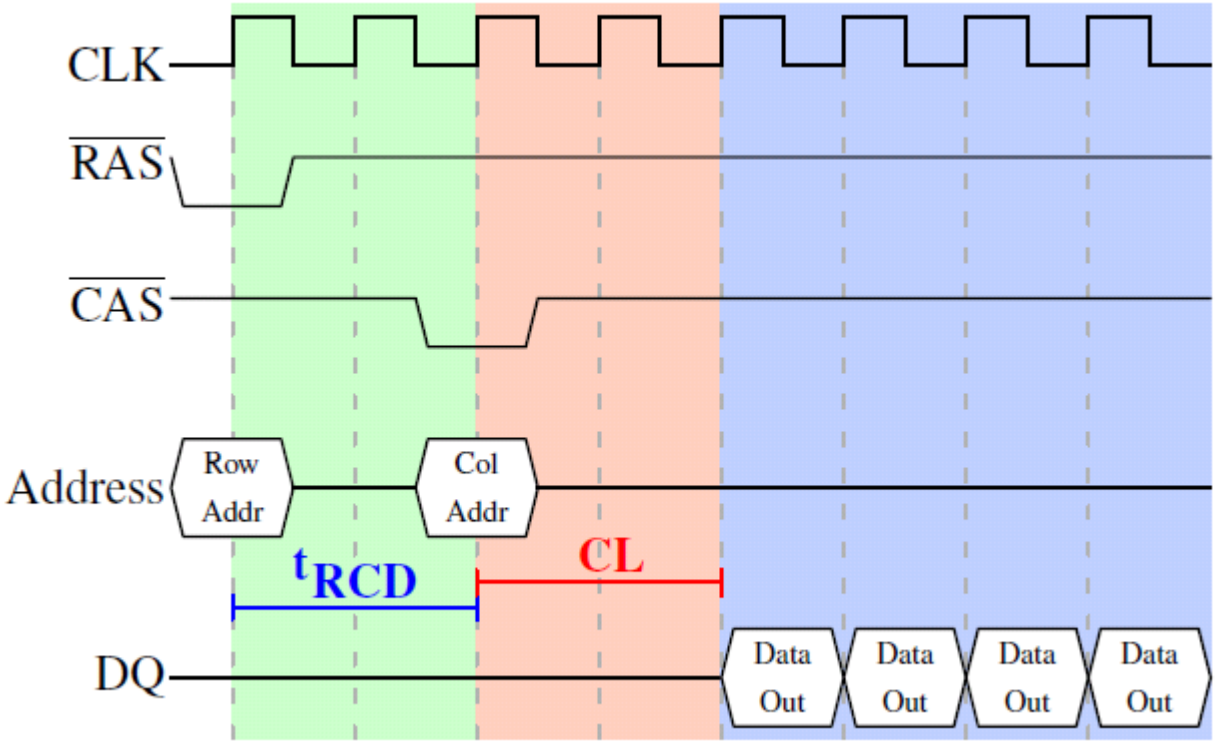

Память SDRAM

- Чтение памяти, необходимо подзаряжать конденсаторы
- Необходимость перезарядки конденсаторов (токи утечки)
- t_{RP} - время предварительной зарядки

- Каждая строка должна быть перезаряжена каждые 7.8 мкс

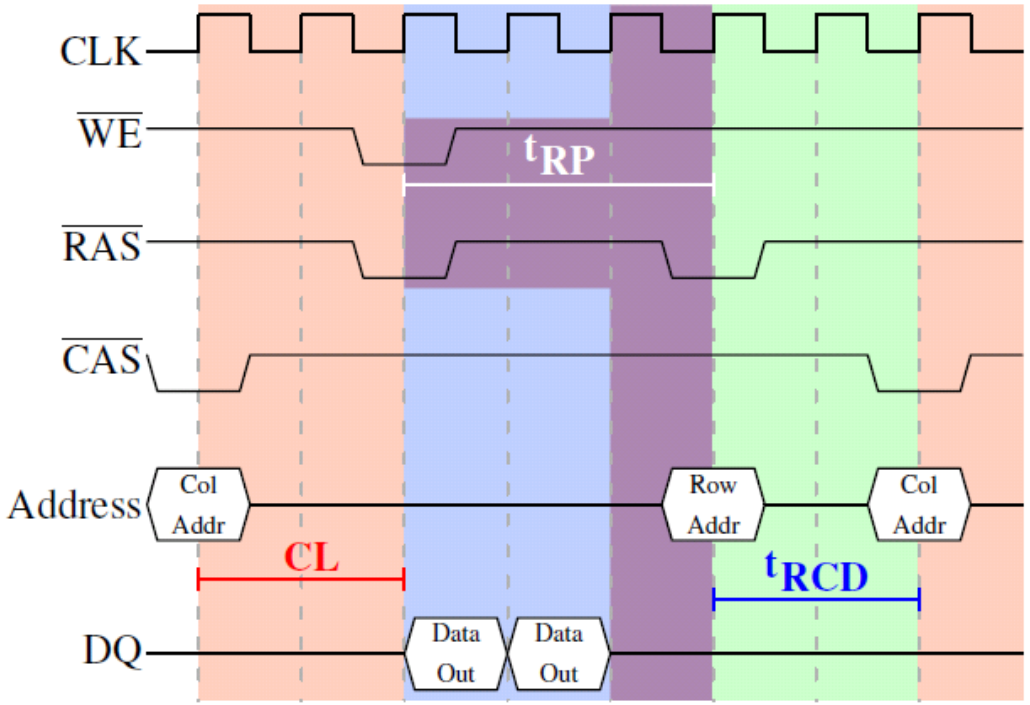

Иерархия памяти:
контроллер – канал – банк

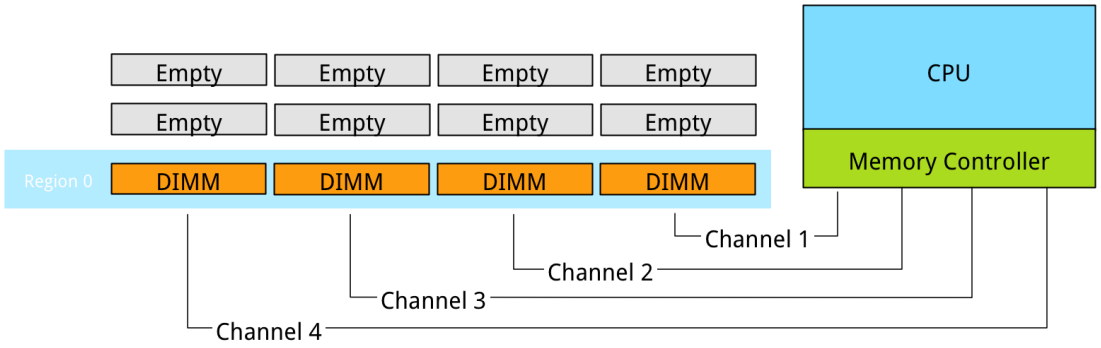

Производительность алгоритмов simple, block, read и bottom-up-hybrid с префетчем в зависимости от числа используемых тредов на сопроцессоре Phi-5110P

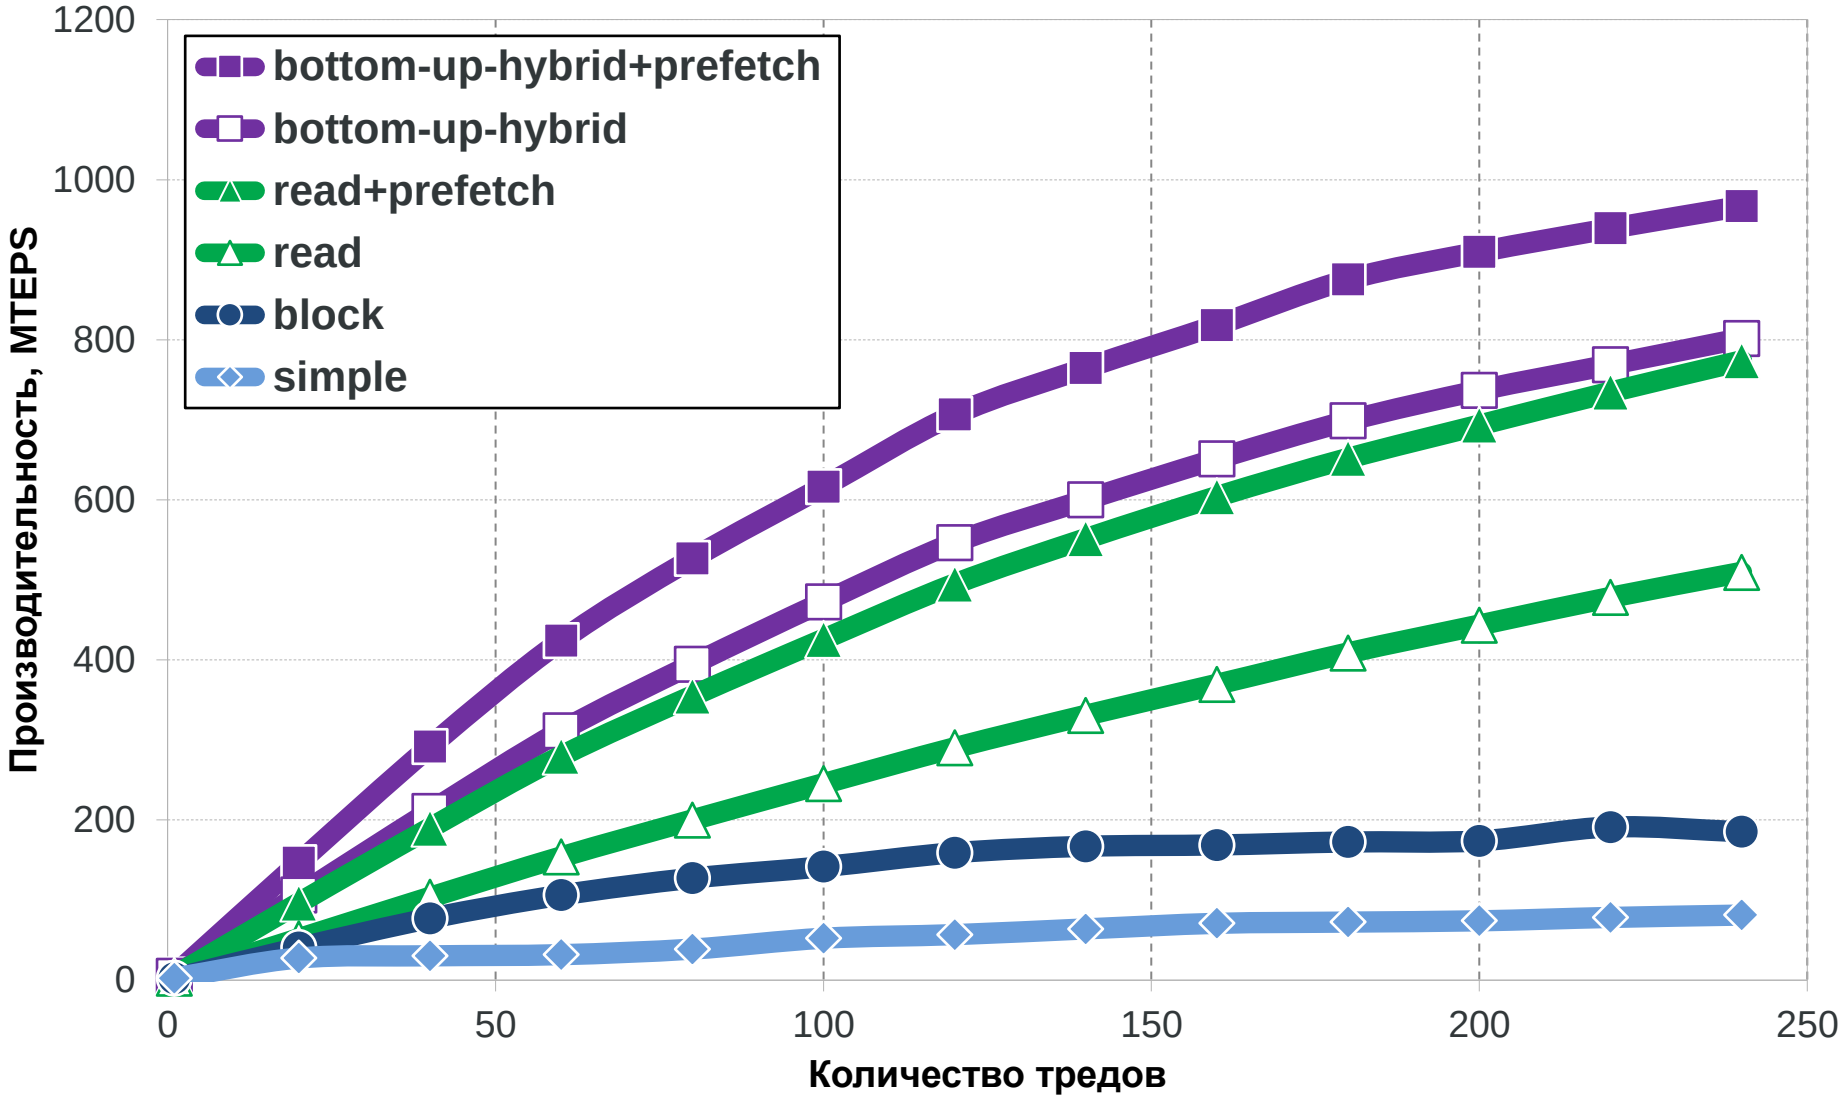

Число вершин в графе: N = 2^{27} (134 млн), средняя связность вершины: k = 8

Улучшение локализации: перестановка вершин

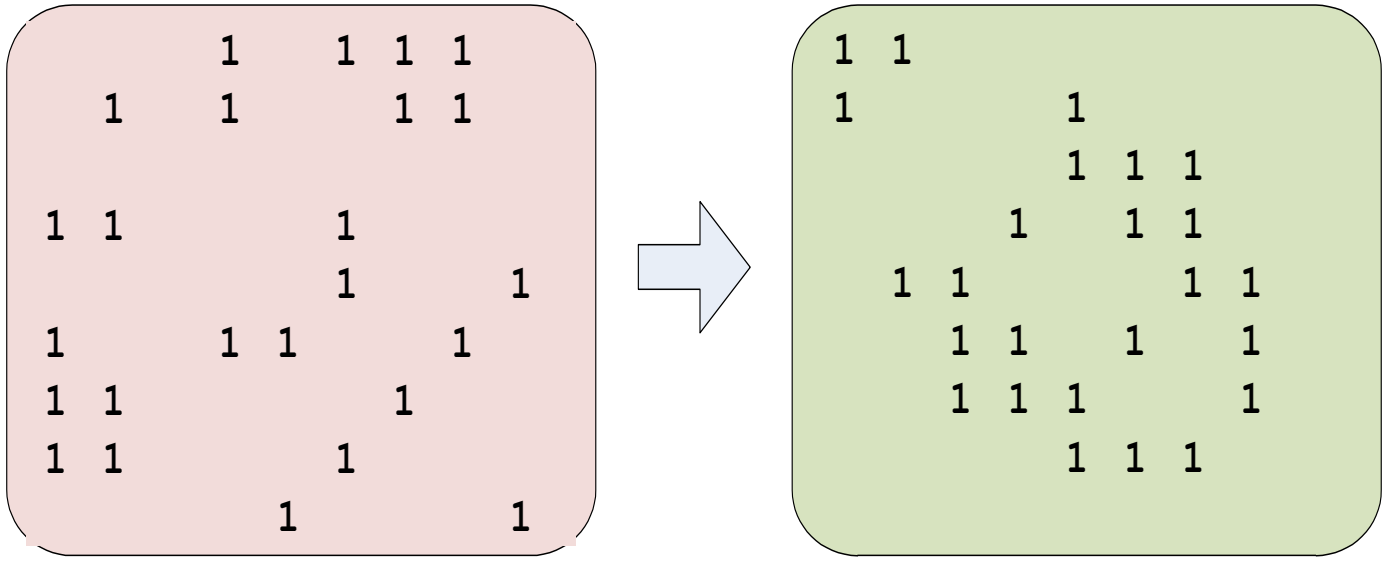

- Матрица смежности приводится к ленточному виду с уменьшением ширины ленты (алгоритм Reverse Cuthill-McKee) => уменьшается количество кэш-промахов
- Списки смежных вершин сортируются => уменьшается количество промахов в TLB
- Использование больших страниц

Производительность различных алгоритмов, с префетчем и перестановками в зависимости от числа используемых тредов на сопроцессоре Phi-5110P

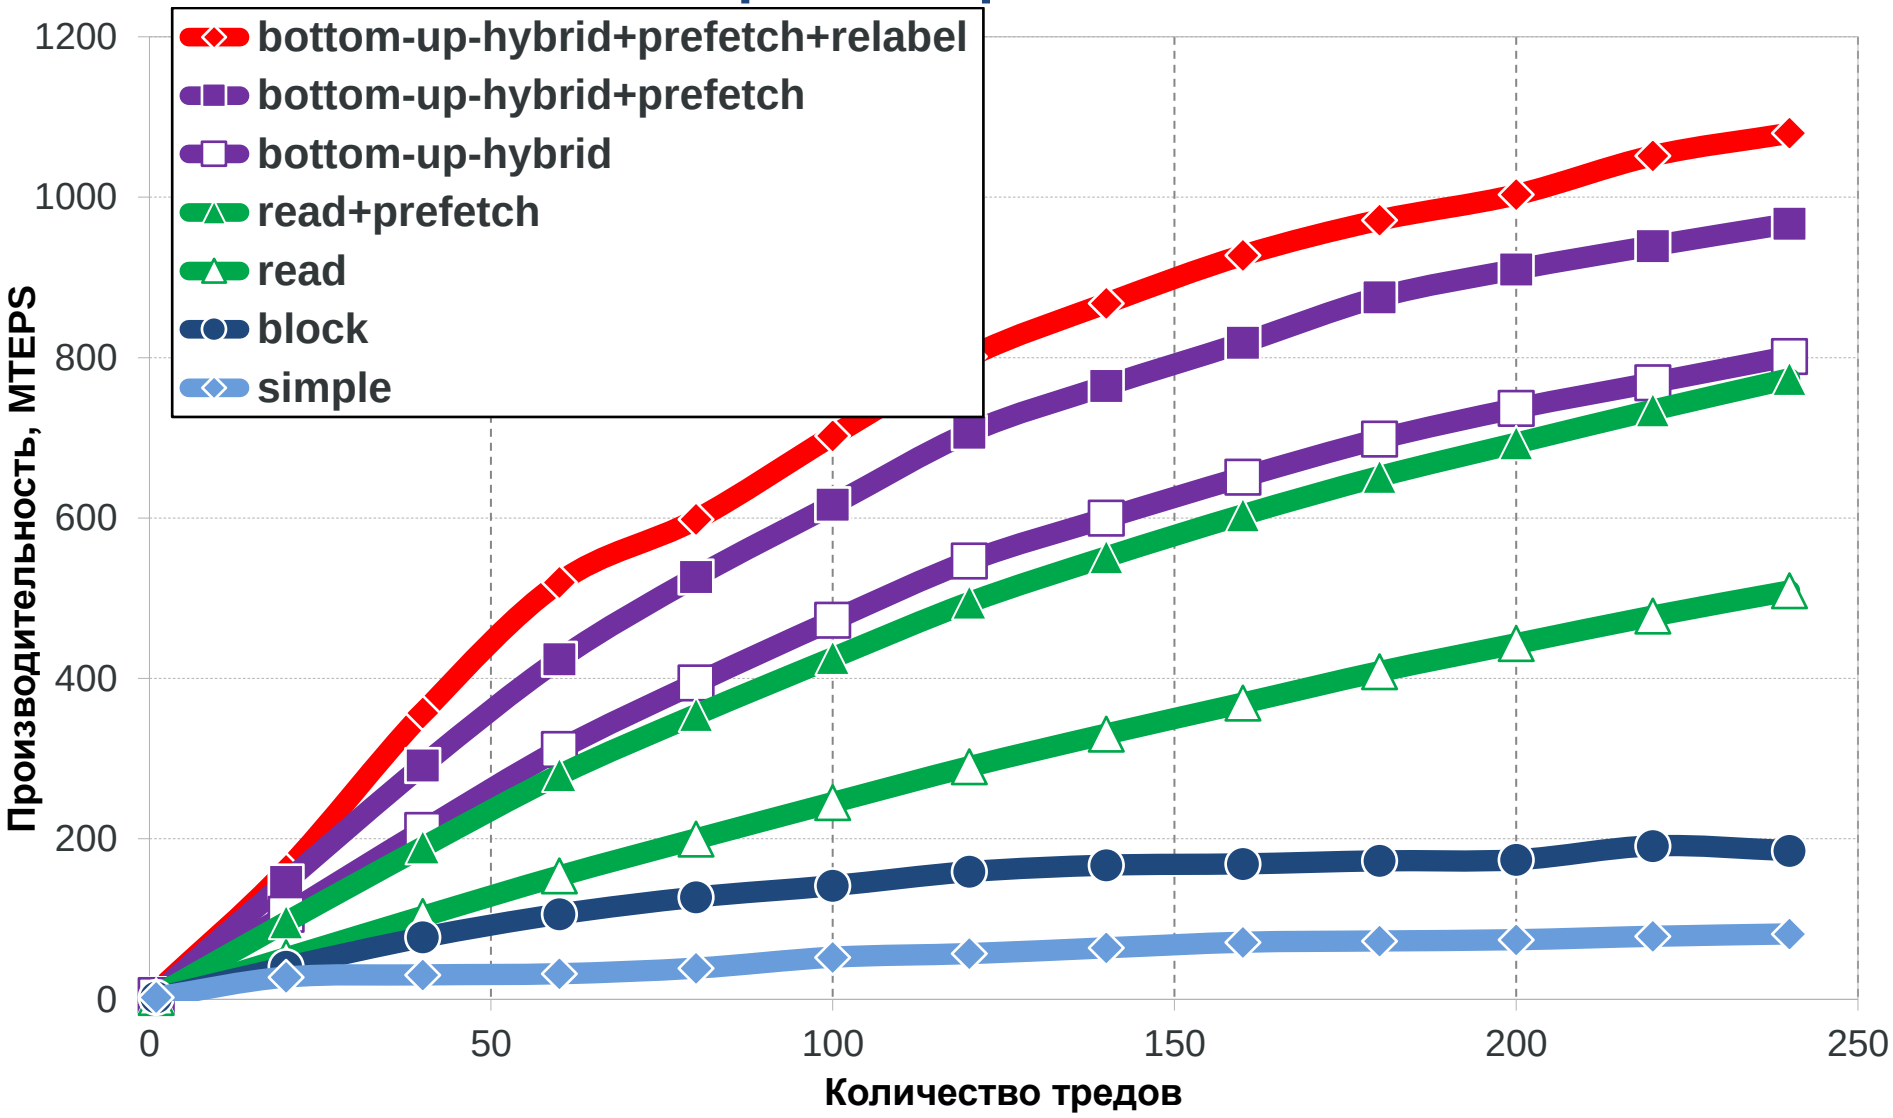

Число вершин в графе: N = 2^{27} (134 млн), средняя связность вершины: k = 8

Распараллеливание: дисбаланс вычислительной нагрузки

- **Проблема: неравномерность** итераций циклов

```
# pragma omp parallel for
for (int u = 0; u < G->n; u++)
      for (int j = G->rowsIndices[u]; j < rowsIndices[u+1]; j++) {
            ……
      }
```

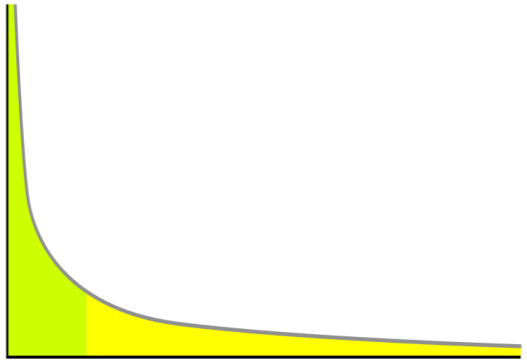

- **Решение 1:** #pragma omp parallel for **schedule (guided)** – для **динамического** распределения вершин по тредам

- **Решение 2:** На этапе предобработки выполнение процедуры Vertex-cut: разделение вершины и **разрезание** списков смежности вершин

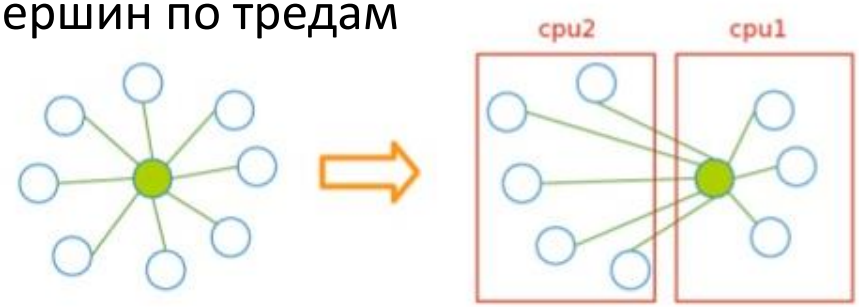

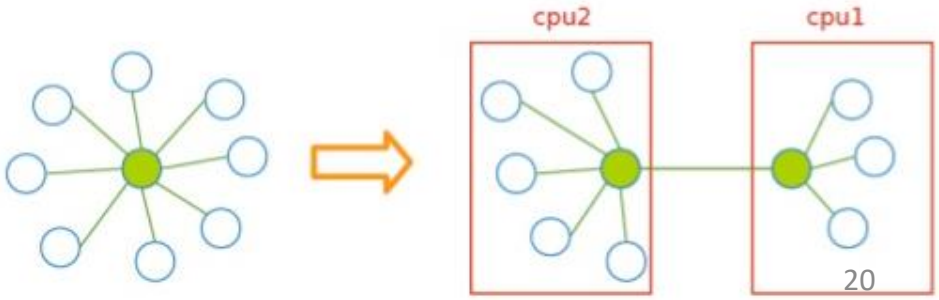

Большой объем памяти

- **Проблема**: постоянная смена данных в кэше, низкие характеристики при случайном доступе
- **Решения** на этапе предобработки:
  - Хранение только половины графа (для неориентированного)
  - Удаление кратных ребер
  - Перестановка вершин (Cuthill-McKee)
  - Сжатие данных
    - edge_id_t: uint64_t --> uint32_t
  - Сортировка ребер каждой вершины
  - Сортировка всех ребер графа

Резюме: проблемы и подходы к решению задач в рамках одного узла

- Выбор оптимального представления графа
- По возможности организация последовательного доступа к данным
- По возможности избегать использовать межпотоковые синхронизации
- Стремиться работать не на задержке обращений к памяти, а на темпе
- Улучшение локализации
- Алгоритмические оптимизации
- Сжатие данных
- Аккуратная работа с памятью внутри NUMA-вычислительного узла
- Балансировка нагрузки
- Аккуратно измерять производительность