



Поиск похожих подпоследовательностей временных рядов на сопроцессорах Intel Xeon Phi

М.Л. Цымблер, А.В. Мовчан

Отдел интеллектуального анализа данных

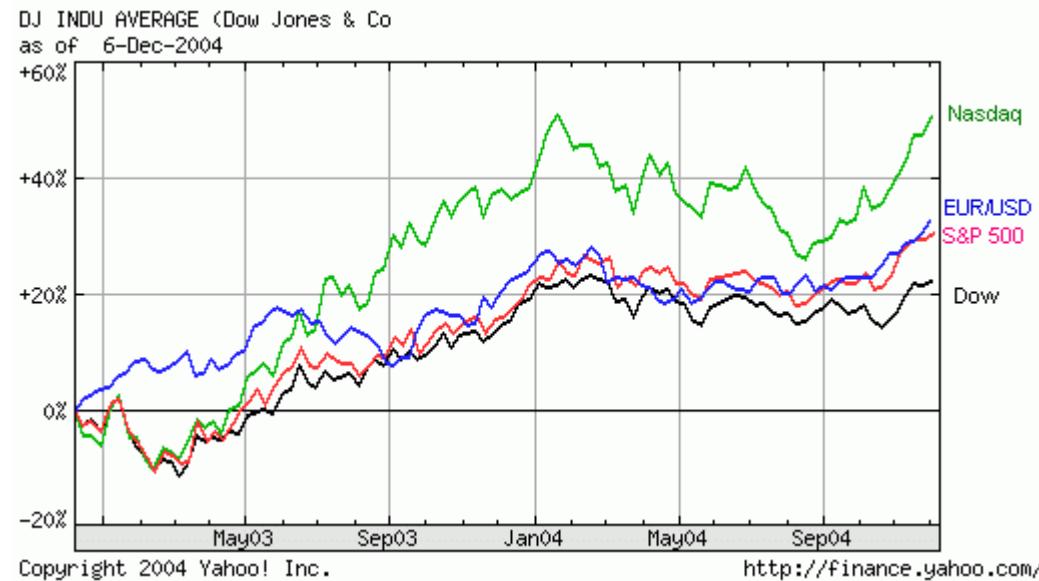
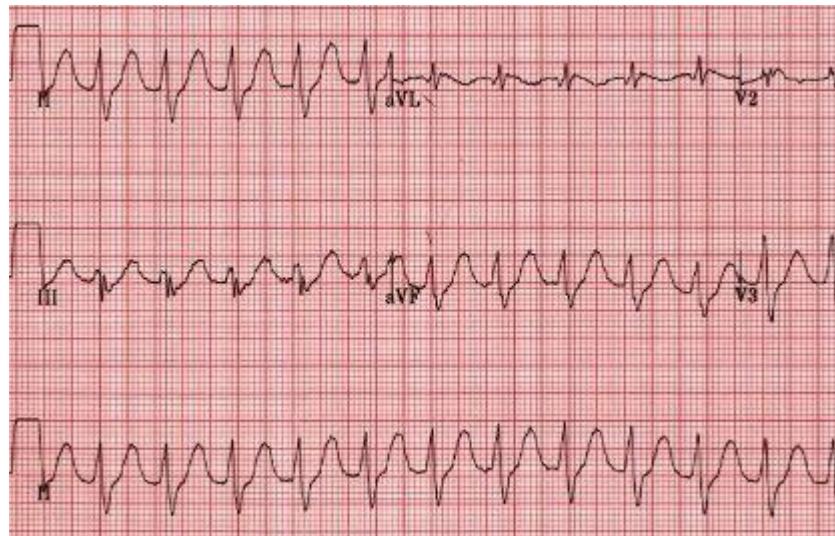
Лаборатории суперкомпьютерного моделирования НИУ ЮУрГУ
Челябинск

кандидат физ.-мат. наук, доцент

mzym@susu.ru

Конференция «Большие Данные в национальной экономике»,
Москва, 21 октября 2014

Временной ряд

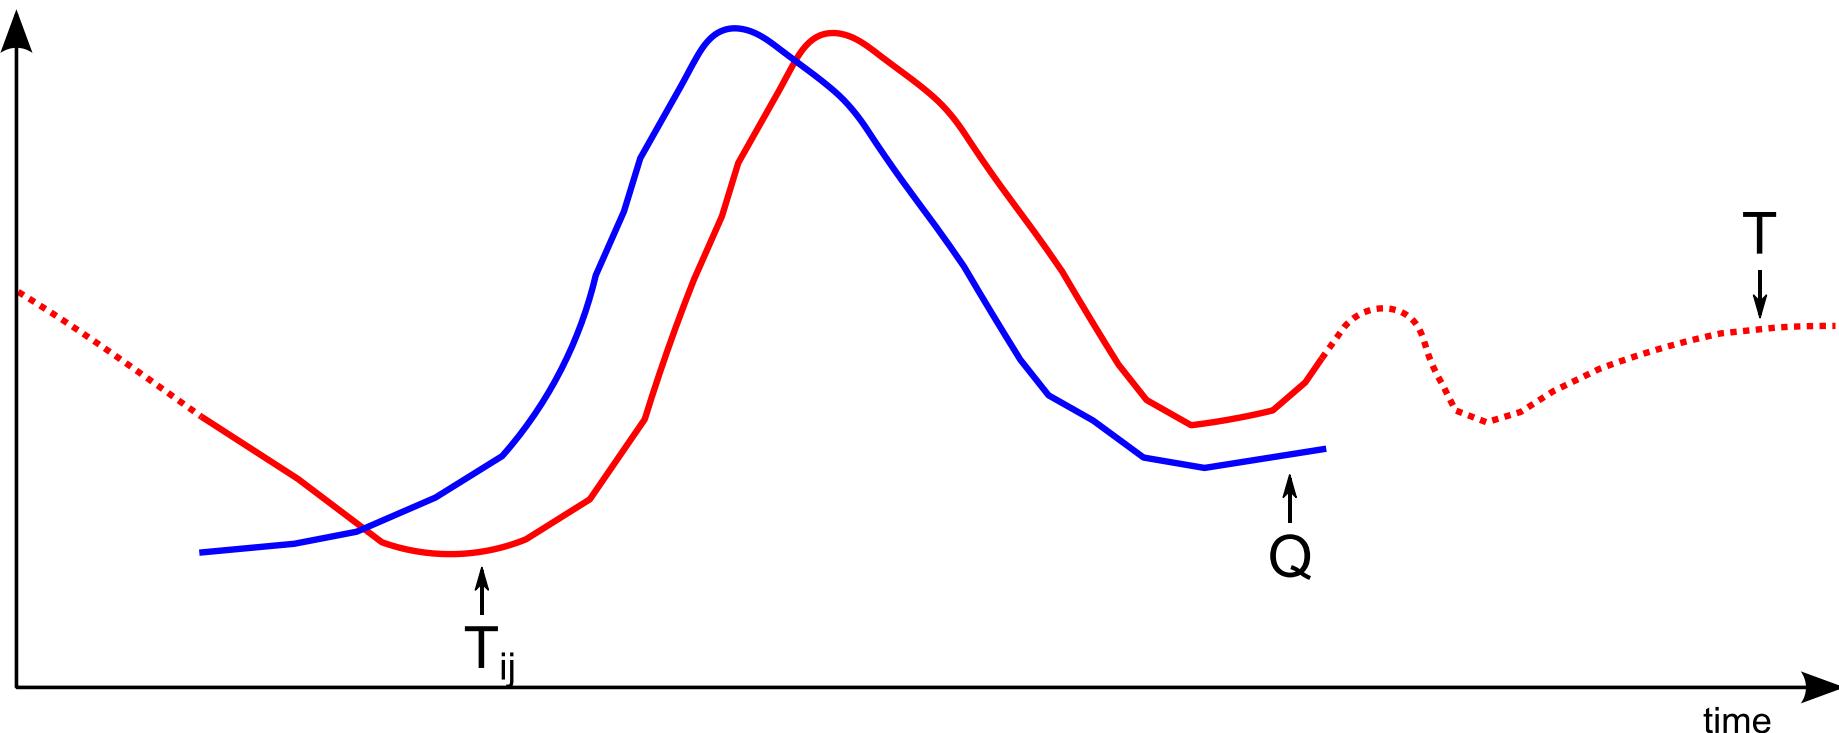


Copyright 2004 Yahoo! Inc.

<http://finance.yahoo.com>



Поиск подпоследовательностей



T

– временной ряд, по которому осуществляется поиск

T_{ij}

– подпоследовательность

Q

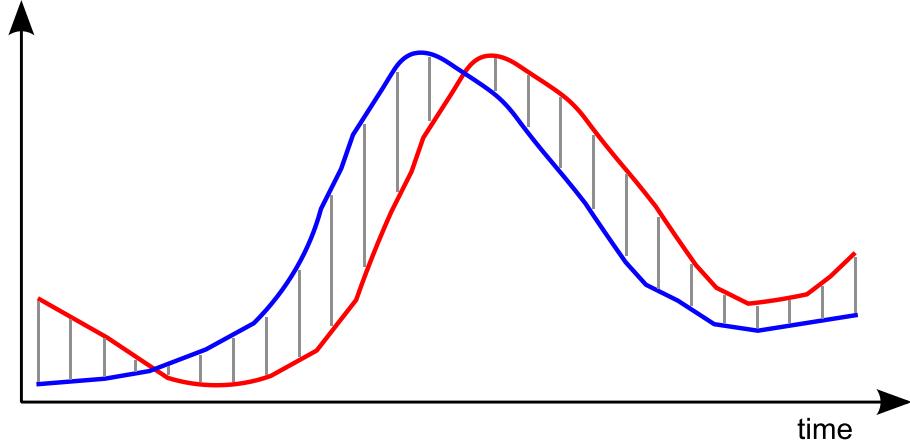
– запрос

D

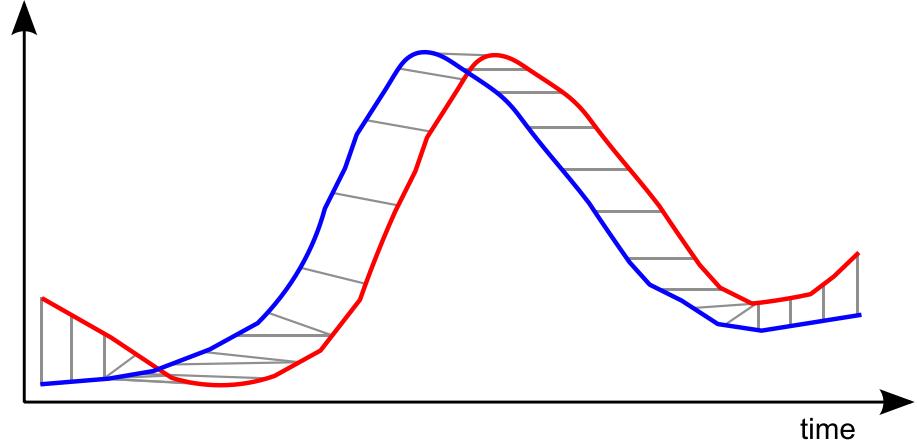
– функция расстояния

Схожесть временных рядов

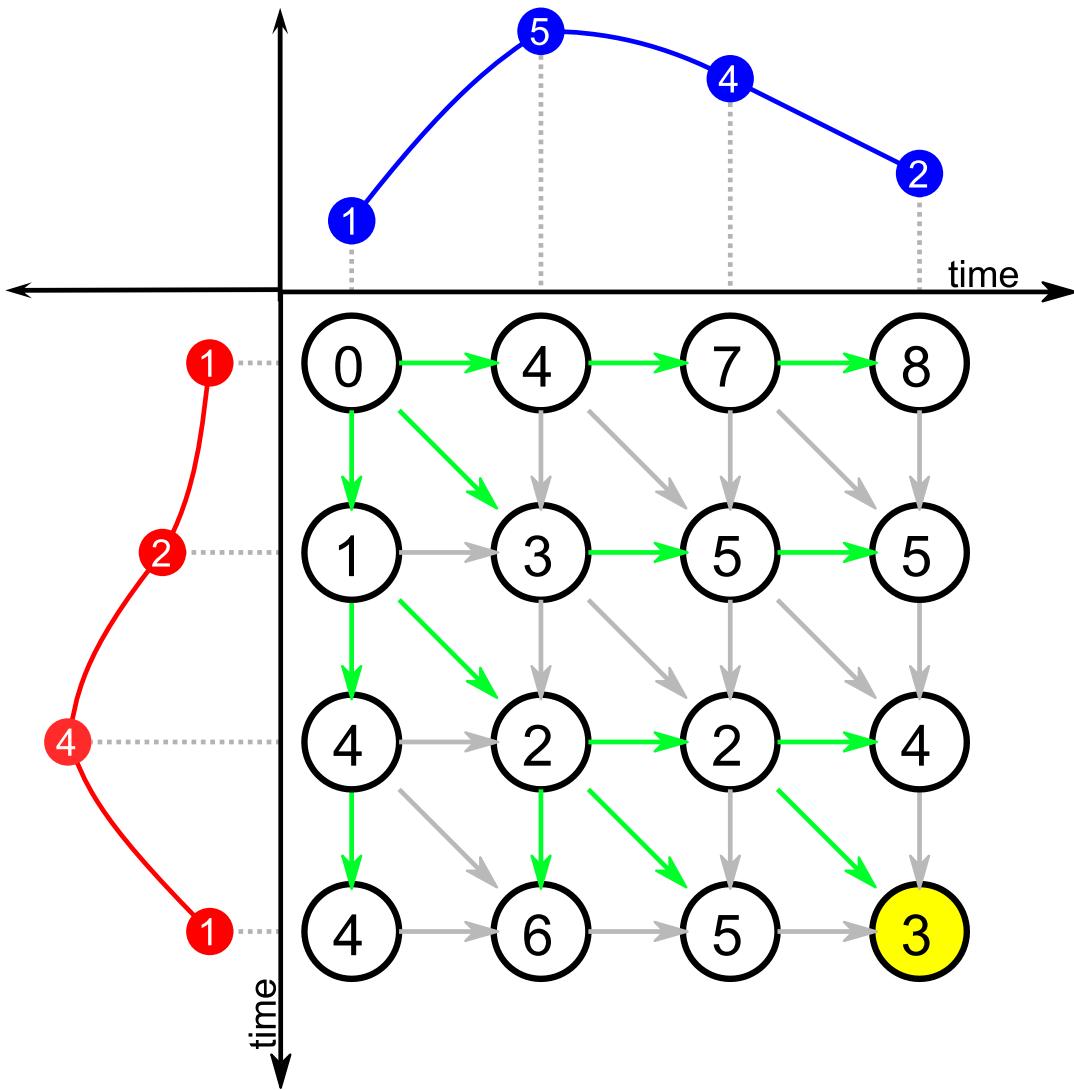
Евклидова метрика



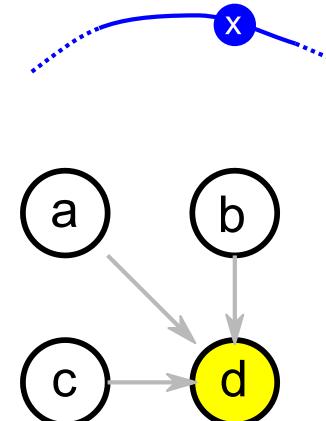
Динамическая трансформация
шкал времени
(DTW, Dynamic Time Warping)



Dynamic Time Warping



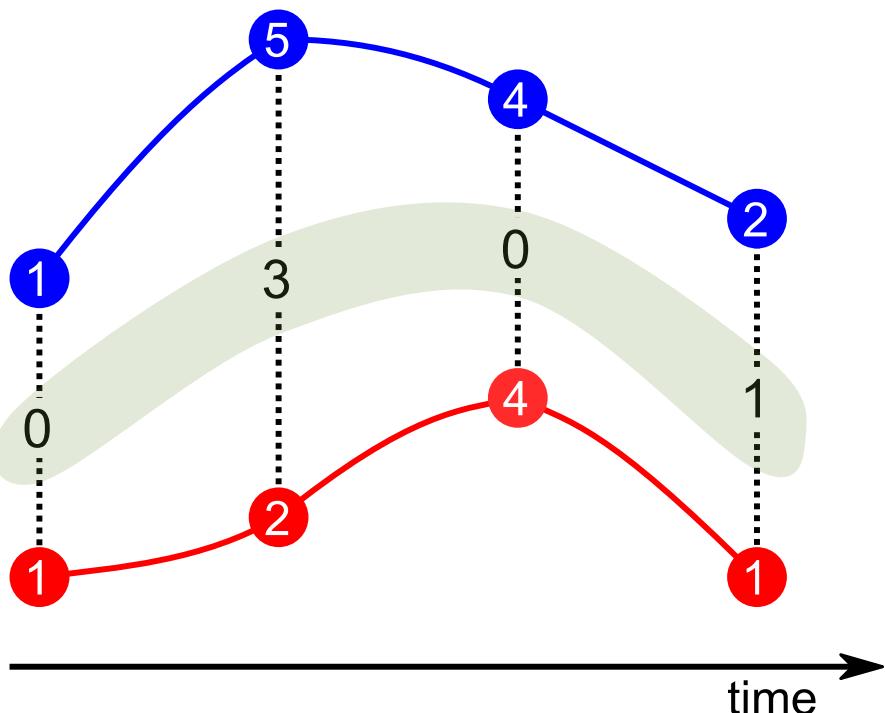
y



$$d = \text{cost} + \min(a, b, c)$$
$$\text{cost} = |x - y|$$

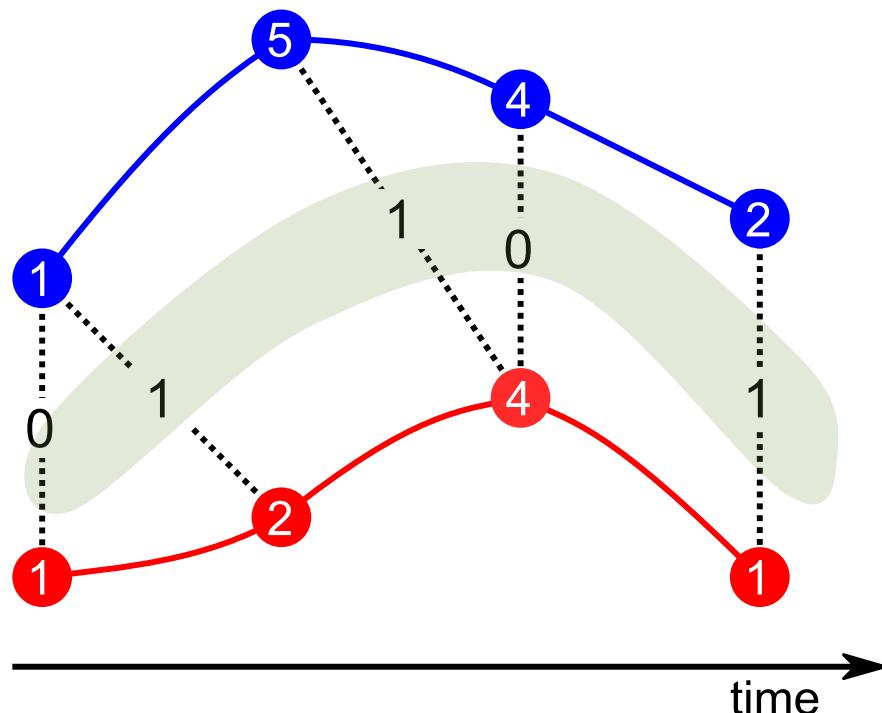
Dynamic Time Warping

Евклидова метрика



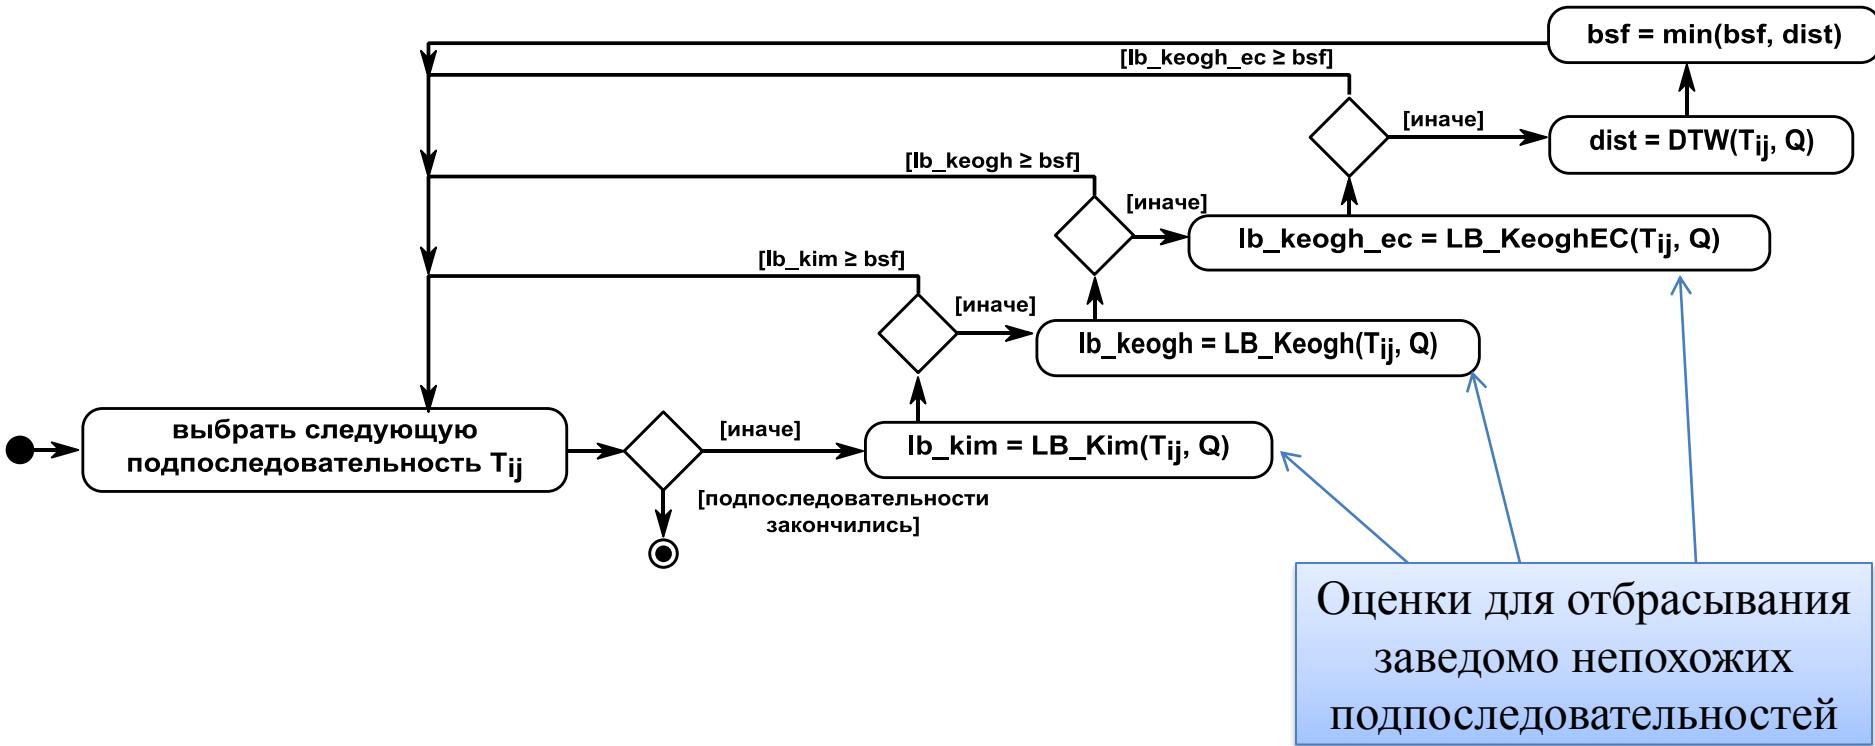
расстояние = 4

Динамическая трансформация
шкалы времени



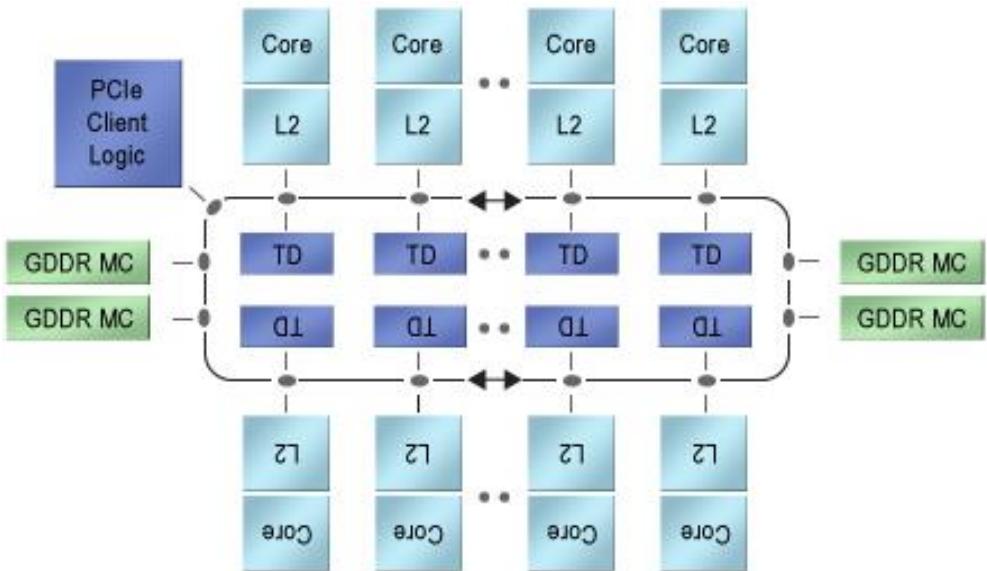
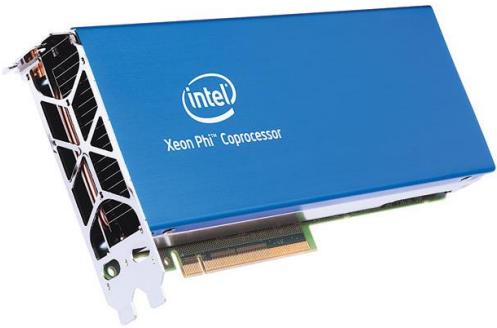
расстояние = 3

Последовательный алгоритм UCR-DTW



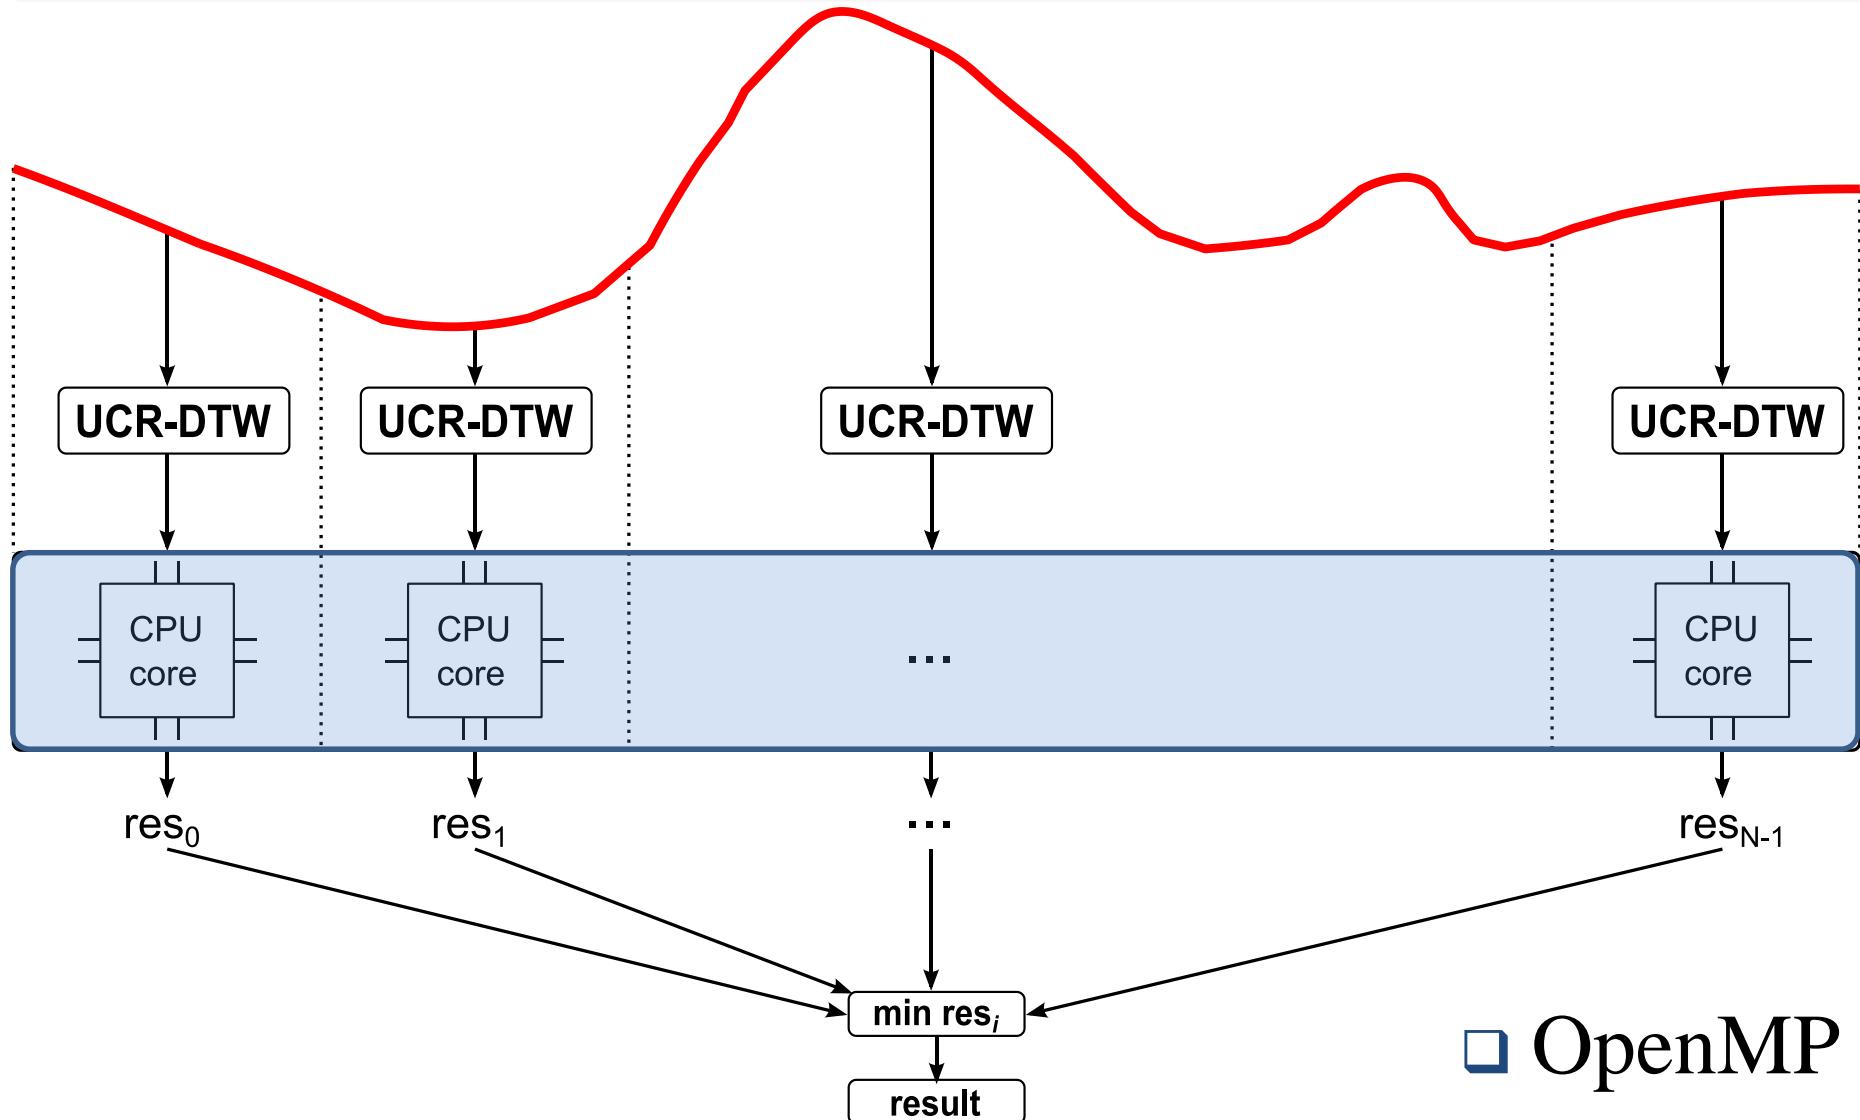
Rakthanmanon T., et al. Searching and Mining Trillions of Time Series Subsequences under Dynamic Time Warping // The 18th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Beijing, China, 12-16 August, 2012. ACM, 2012. P. 262–270.

Сопроцессор Intel Xeon Phi



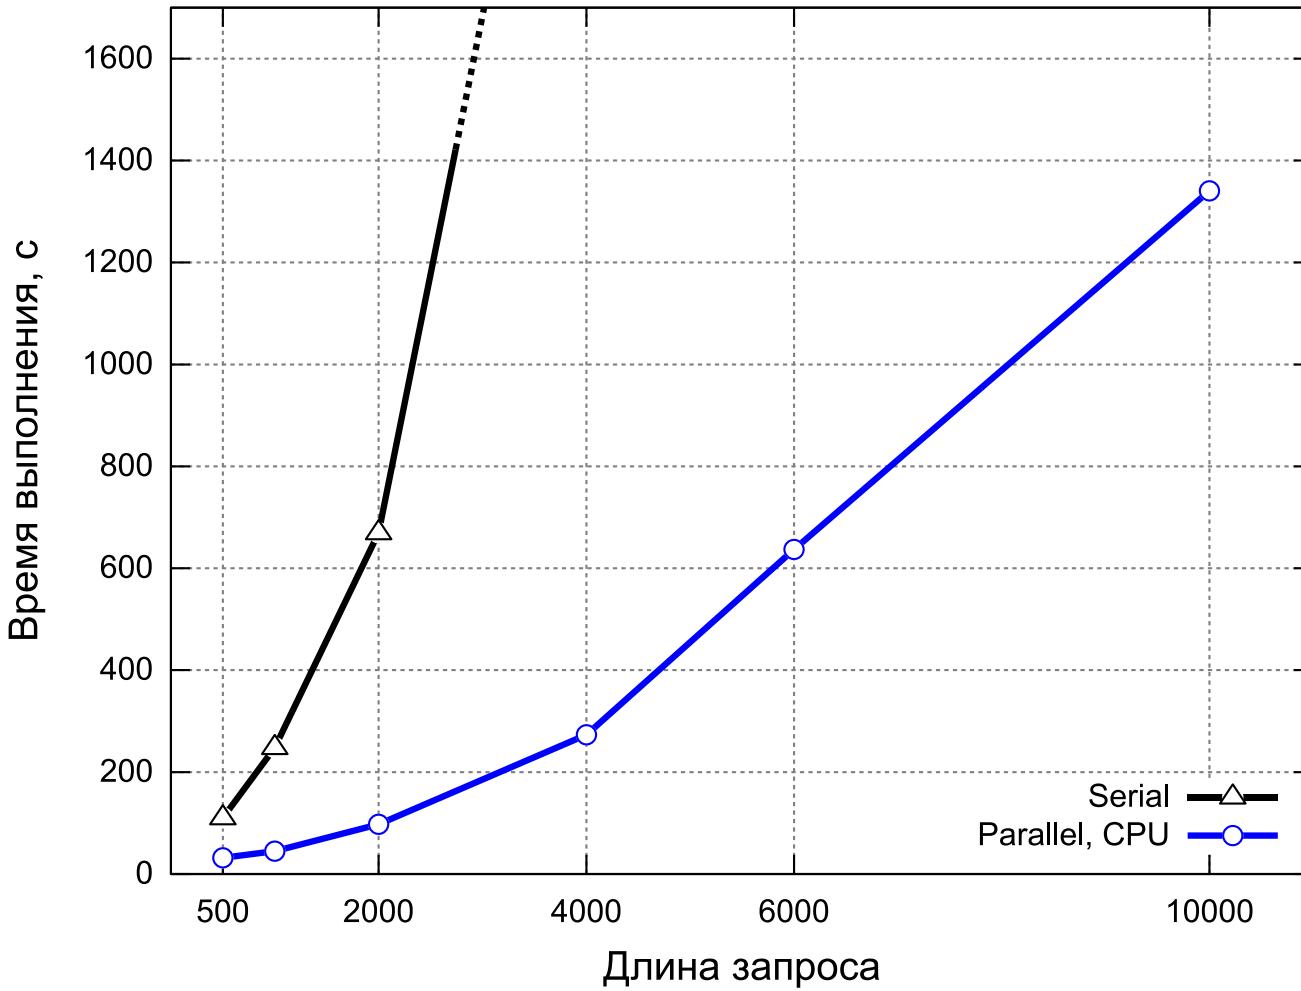
- Native mode
 - независимое исполнение на сопроцессоре
- Offload mode
 - исполнение на процессоре, выгрузка интенсивных вычислений на сопроцессор
- Symmetric mode
 - исполнение как приложения MPI

Параллельный алгоритм для CPU



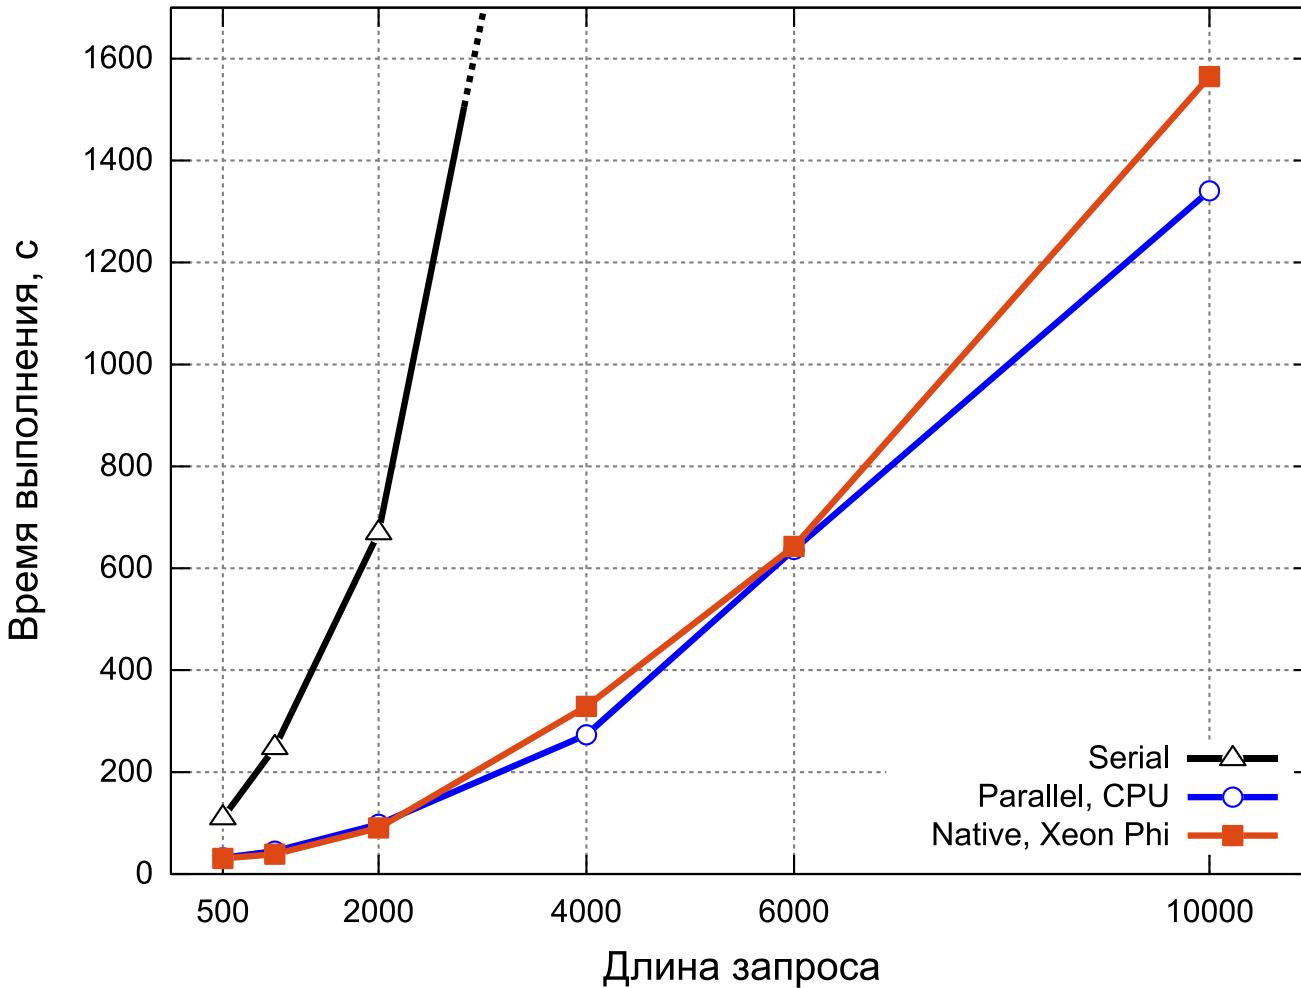
Результаты экспериментов, параллельный алгоритм для CPU

Данные: random walk, 10^9 точек



Результаты экспериментов, native mode

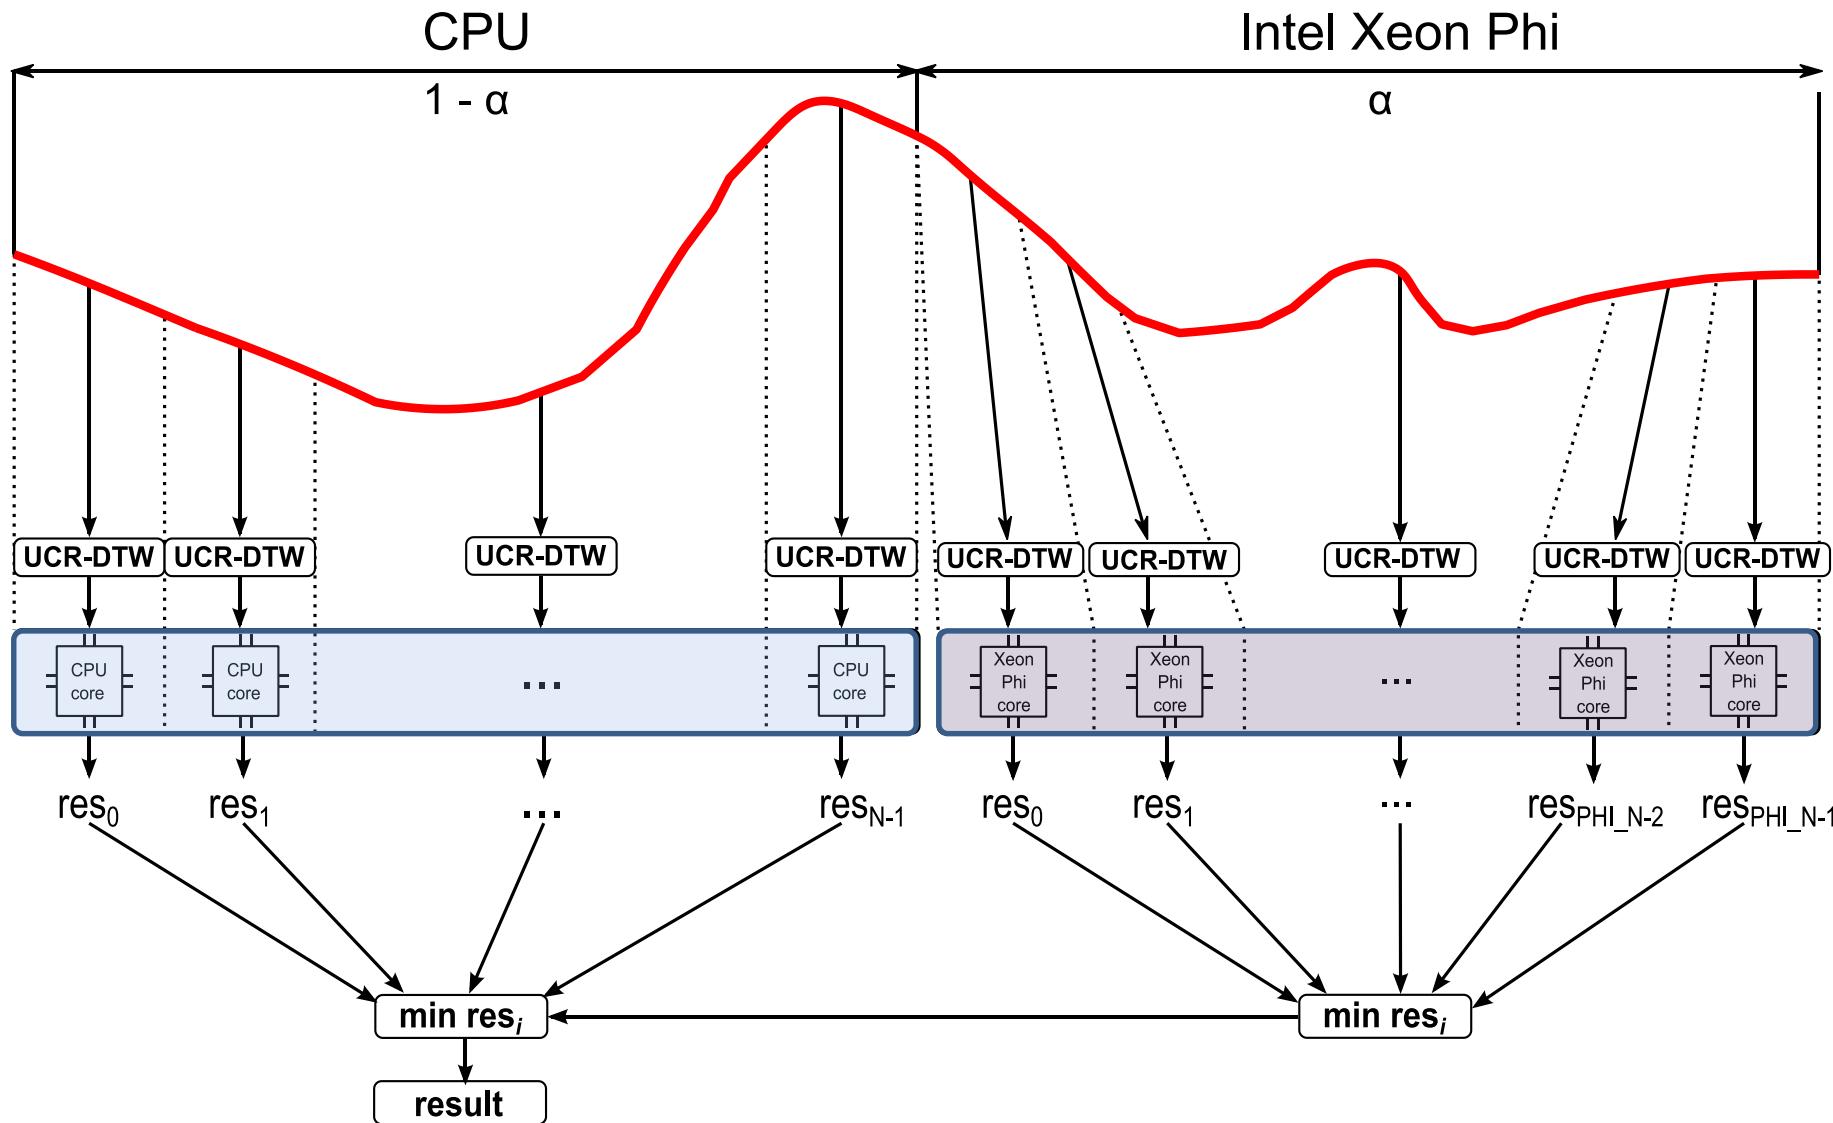
Данные: random walk, 10^9 точек



LB_Kim	$O(1)$
LB_Keogh	$O(n)$
LB_KeoghEC	$O(n)$
DTW	$O(n^2)$

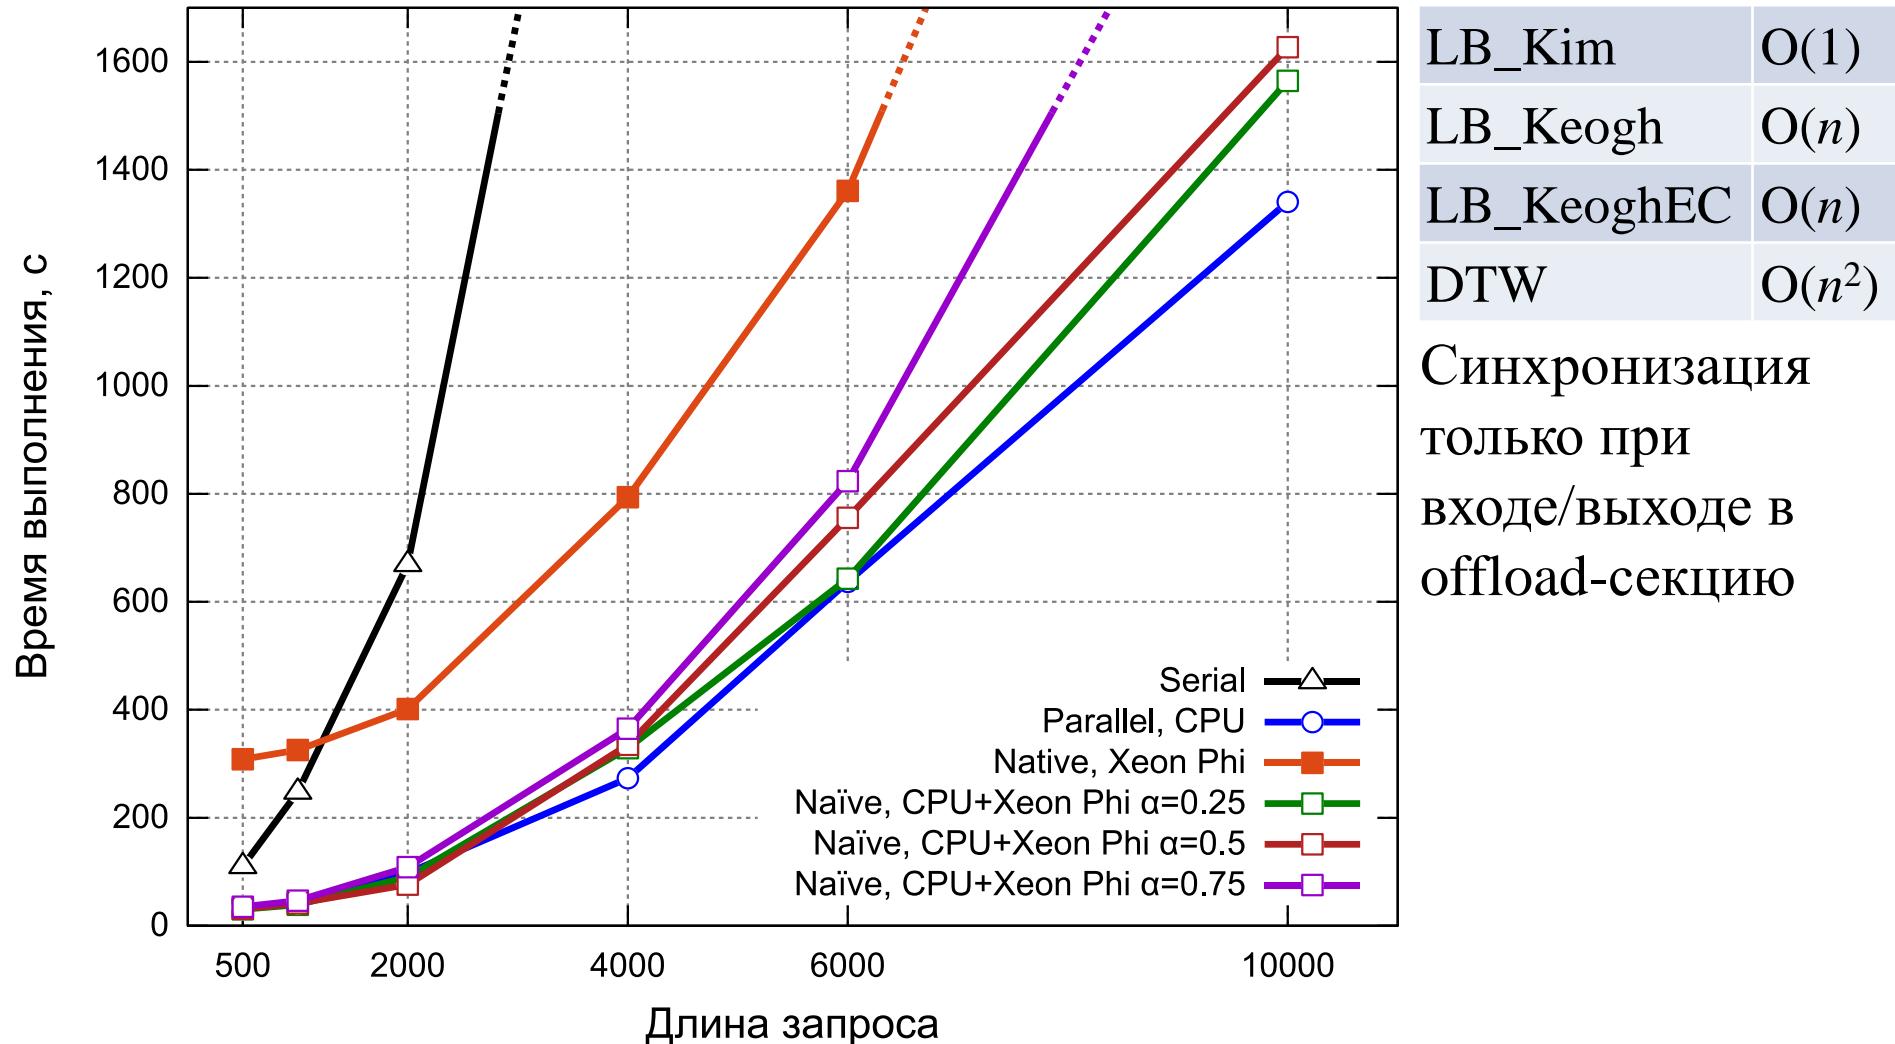
Время загрузки
в память Phi: ≈ 300 с

Найвный алгоритм для Xeon Phi

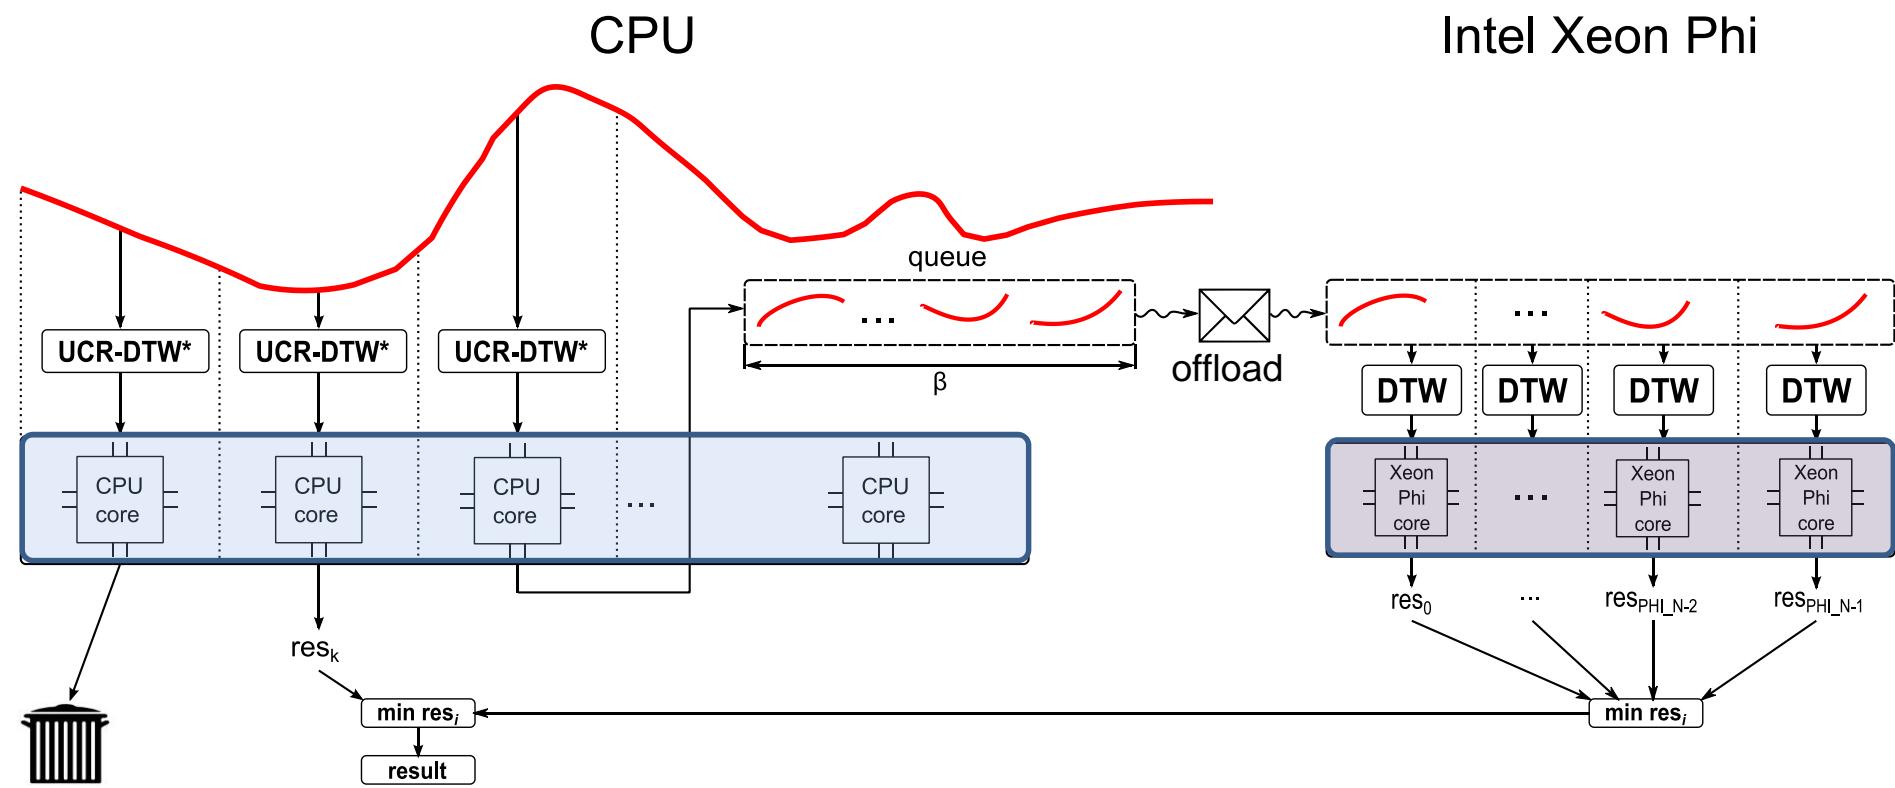


Результаты экспериментов, наивный алгоритм

Данные: random walk, 10^9 точек



Параллельный алгоритм для Xeon Phi



Векторизация: до

```
double DTW(a: array [1..m], b: array [1..m], r: int) {
    cost := array [1..m]
    cost_prev := array [1..m]

    for i := 1 to m
        cost[i] = infinity
        cost_prev[i] = infinity

    cost_prev[1] = dist(a[1], b[1])

    for j := max(2, i-r) to min(m, i+r)
        cost_prev[j] := cost_prev[j-1] + dist(a[1], b[j])

    for i := 2 to m
        for j := max(1, i-r) to min(m, i+r)
            c := d(a[i], b[j])
            cost[j] := c + min(cost[j-1], cost_prev[j-1], cost_prev[j])
            swap(cost, cost_prev)

    return cost_prev[m]
}
```

Векторизация: после

```
double DTW(a: array [1..m], b: array [1..m], r: int) {  
    cost := array [1..m]  
    cost_prev := array [1..m]  
    for i := 1 to m  
        cost[i] = infinity  
        cost_prev[i] = infinity  
    cost_prev[1] = dist(a[1], b[1])  
    for j := max(2, i-r) to min(m, i+r)  
        cost_prev[j] := cost_prev[j-1] + dist(a[1], b[j])  
    for i := 2 to m  
        for j := max(1, i-r) to min(m, i+r)  
            cost[j] = min(cost_prev[j-1], cost_prev[j])  
        for j := max(1, i-r) to min(m, i+r)  
            c := dist(a[i], b[j])  
            cost[j] := c + min(cost[j-1], cost[j])  
    swap(cost, cost_prev)  
    return cost_prev[m]  
}
```

Эксперименты

□ Аппаратная платформа

— Процессор

- Intel Xeon X5680
- 6 ядер по 3.33 GHz
- 0.371 Тфлопс

— Сопроцессор

- Intel Xeon Phi SE10X
- 61 ядро по 1.1 GHz
- 1.076 Тфлопс

□ Данные

— Синтетические

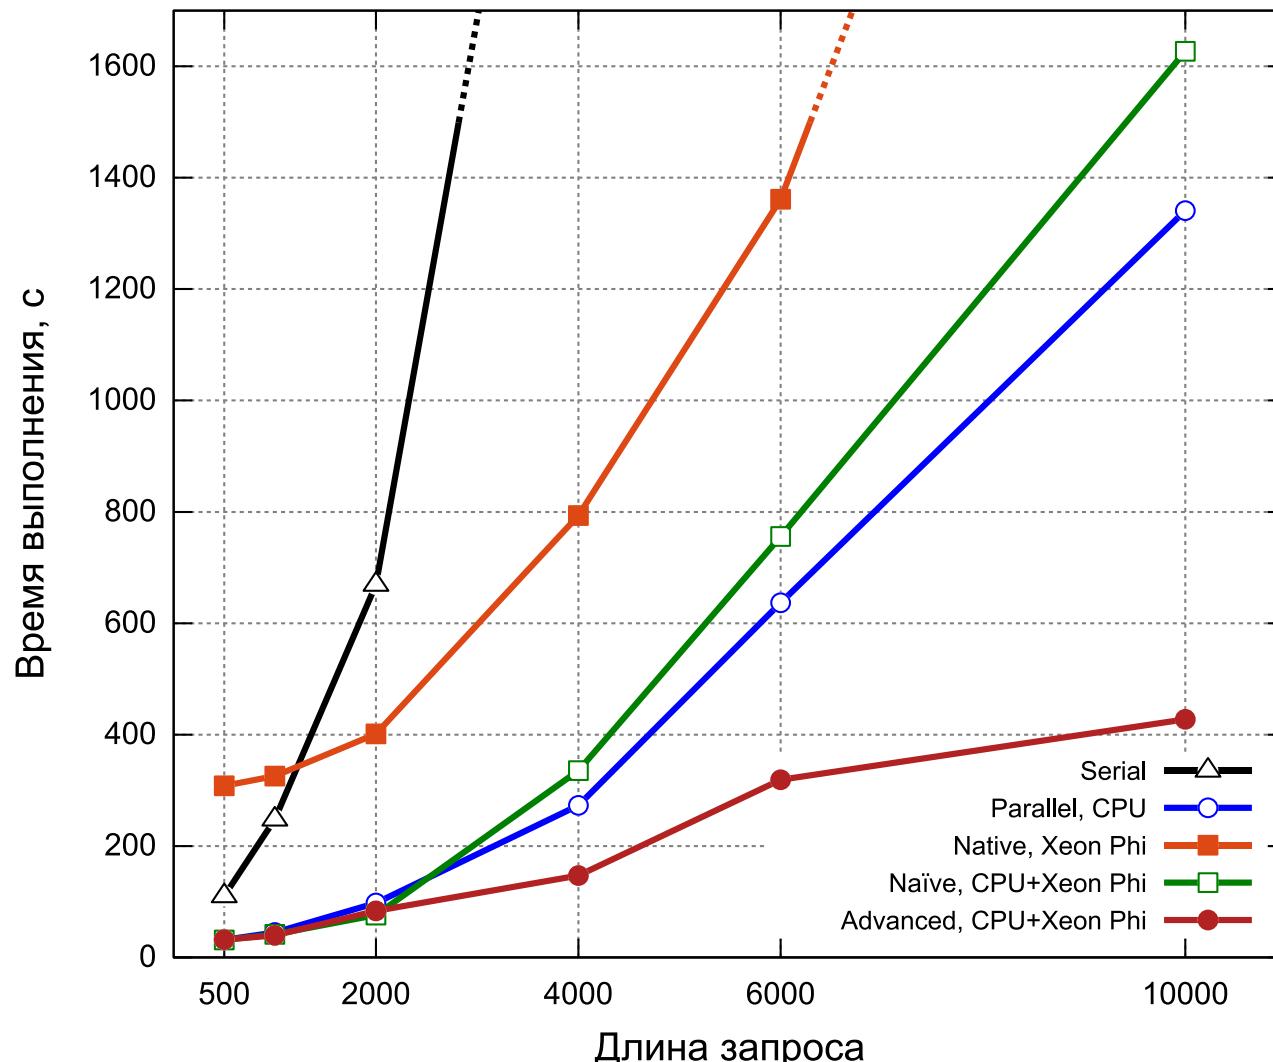
- random walk, 10^9 точек данных

— Реальные

- ЭКГ, $2 \cdot 10^7$ точек данных (22 час. при частоте дискретизации 250 Гц)

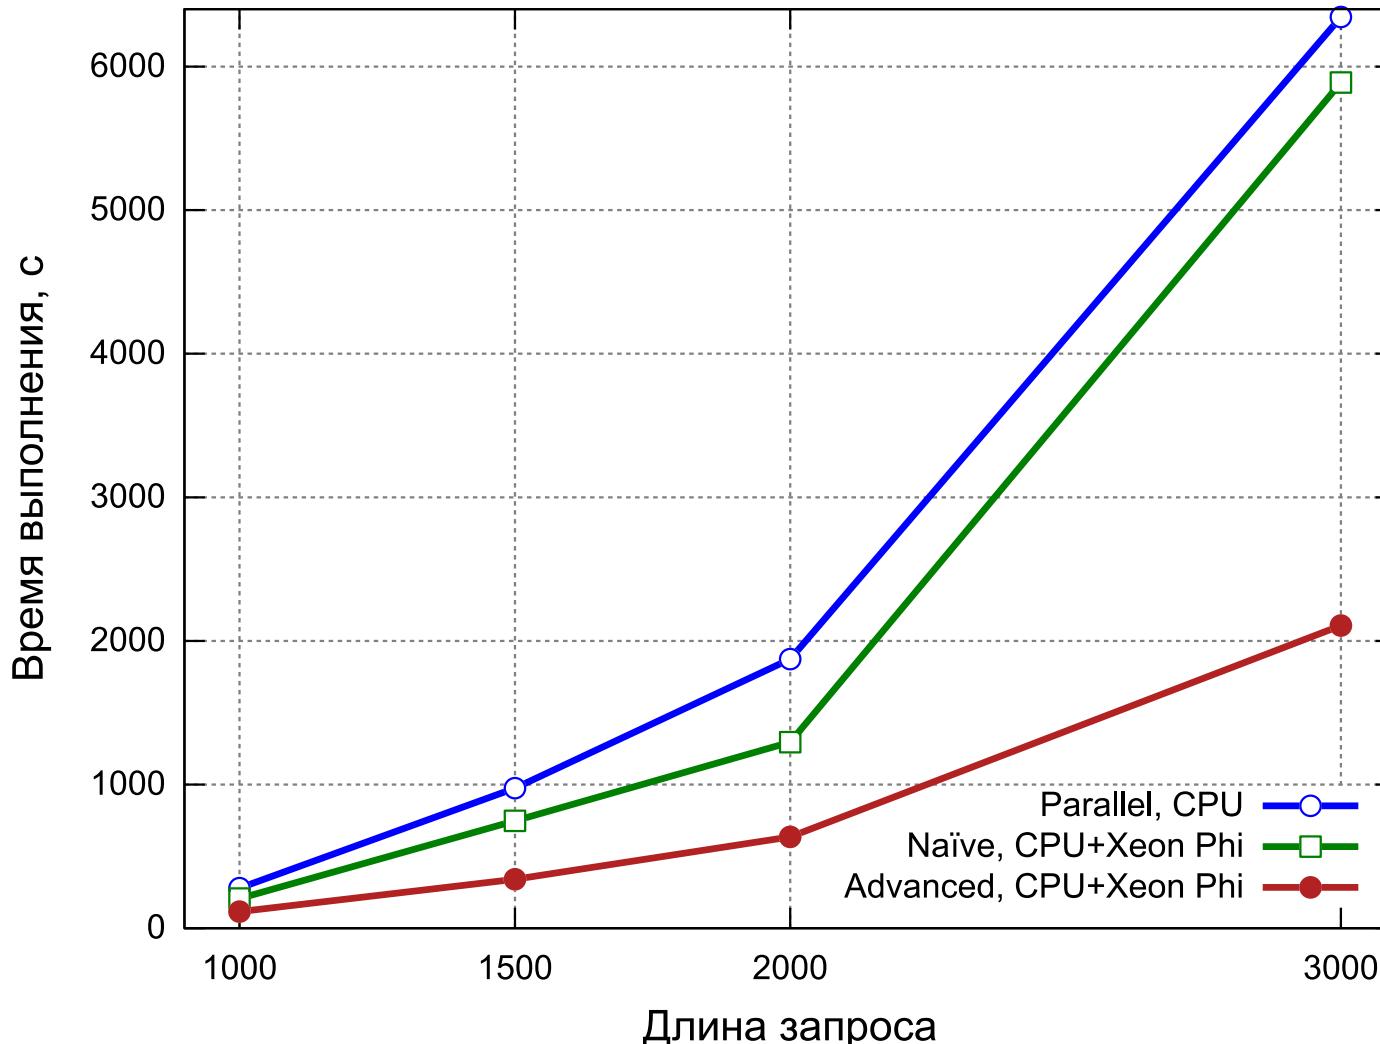
Эксперименты: синтетич. данные

Данные: random walk, 10^9 точек

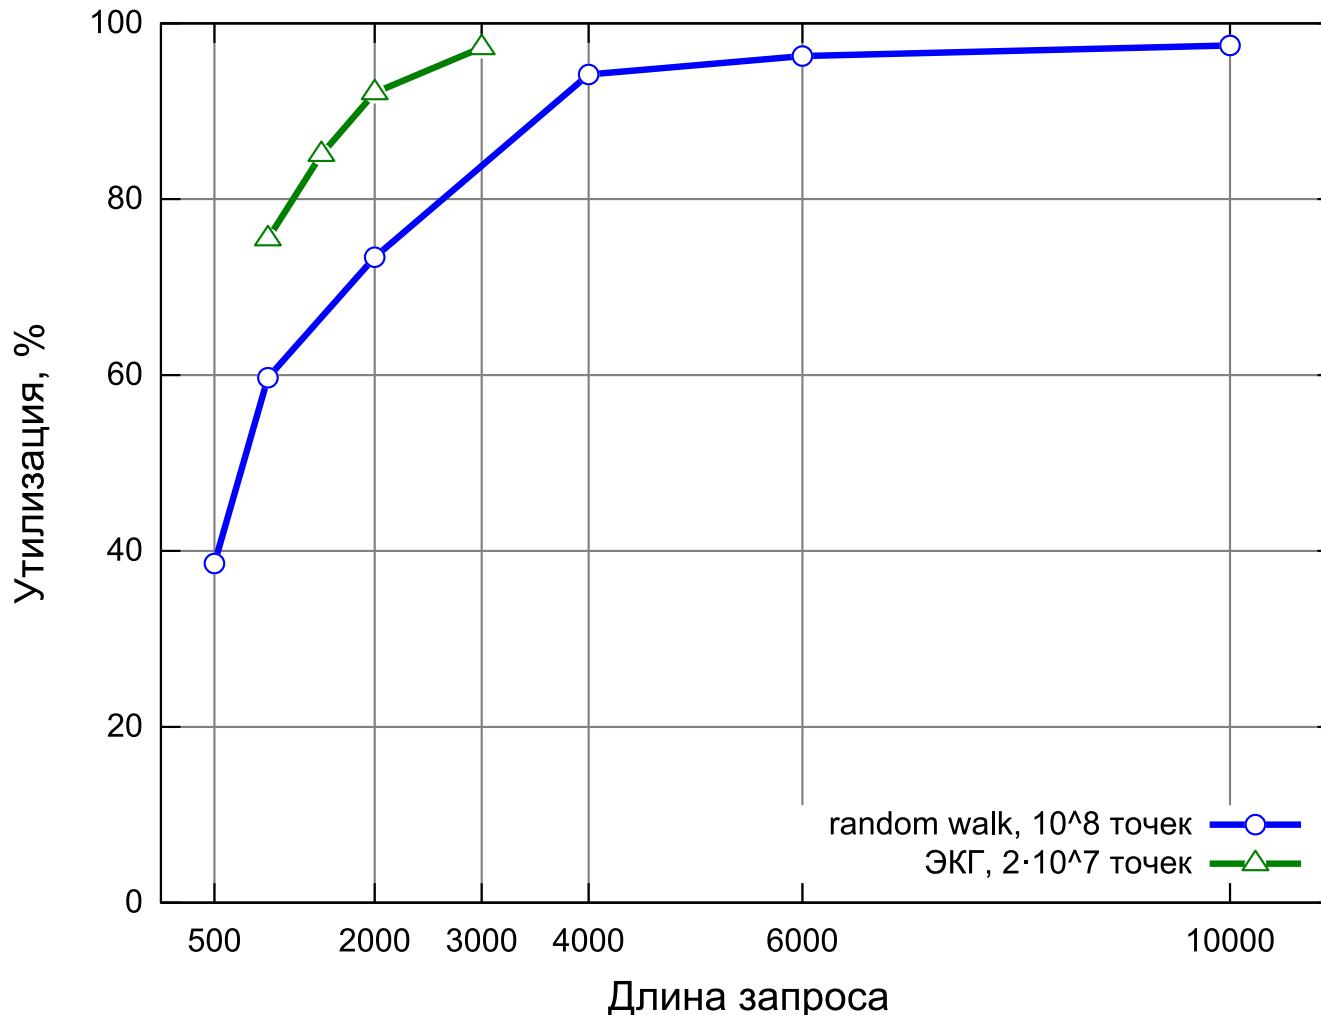


Эксперименты: ЭКГ

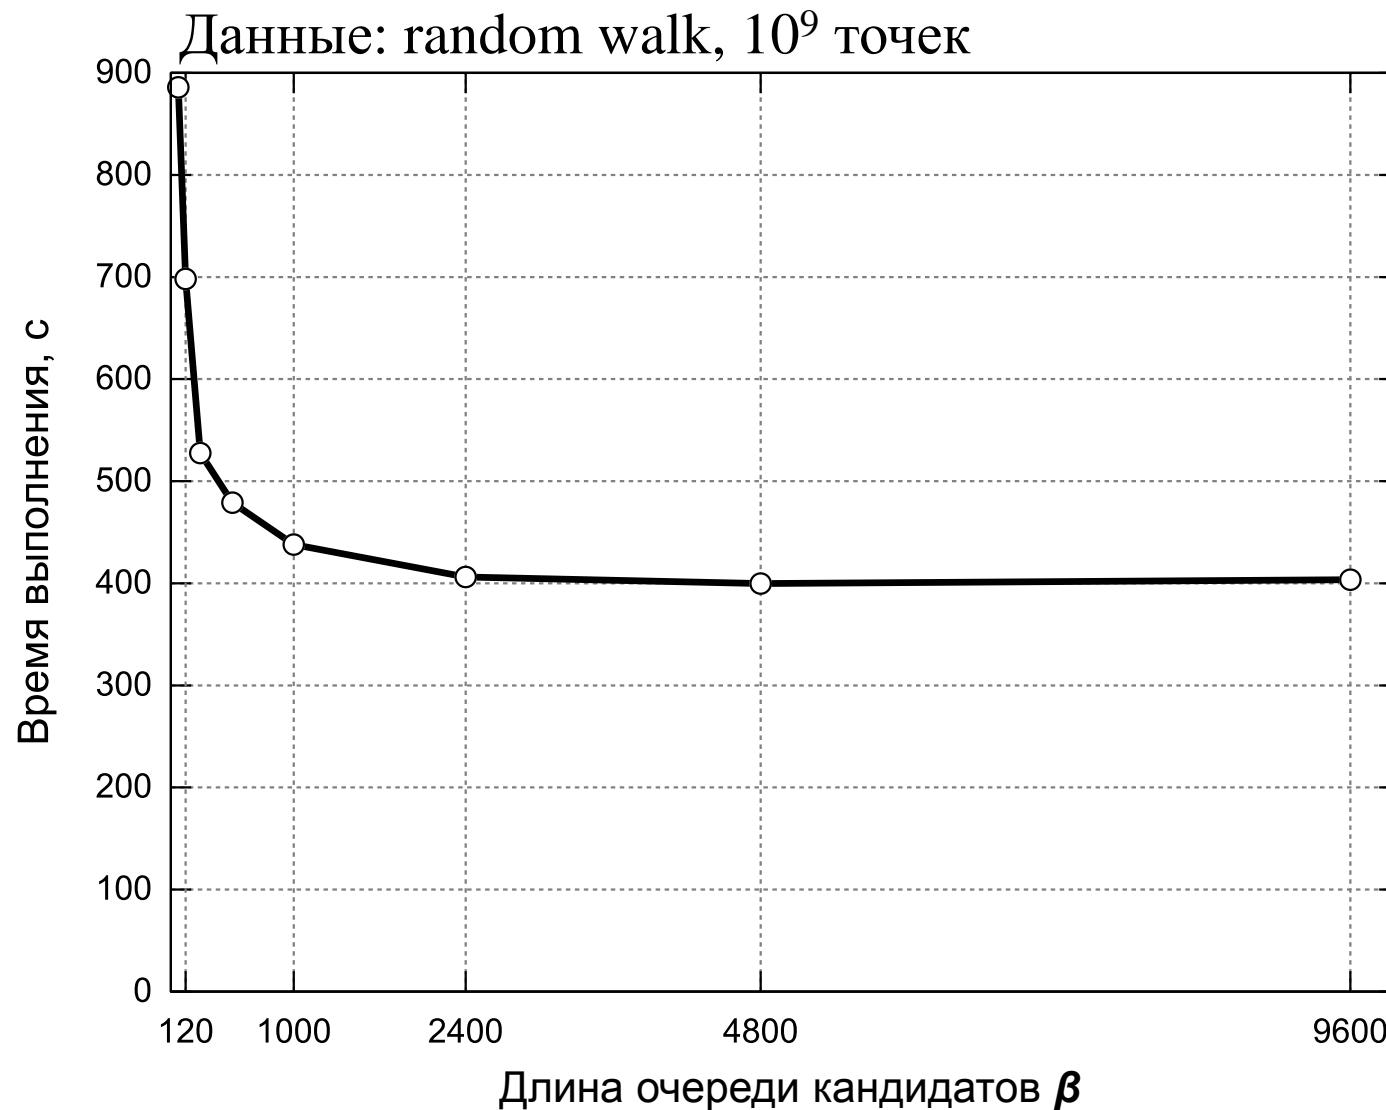
Данные: ЭКГ, $2 \cdot 10^7$ точек



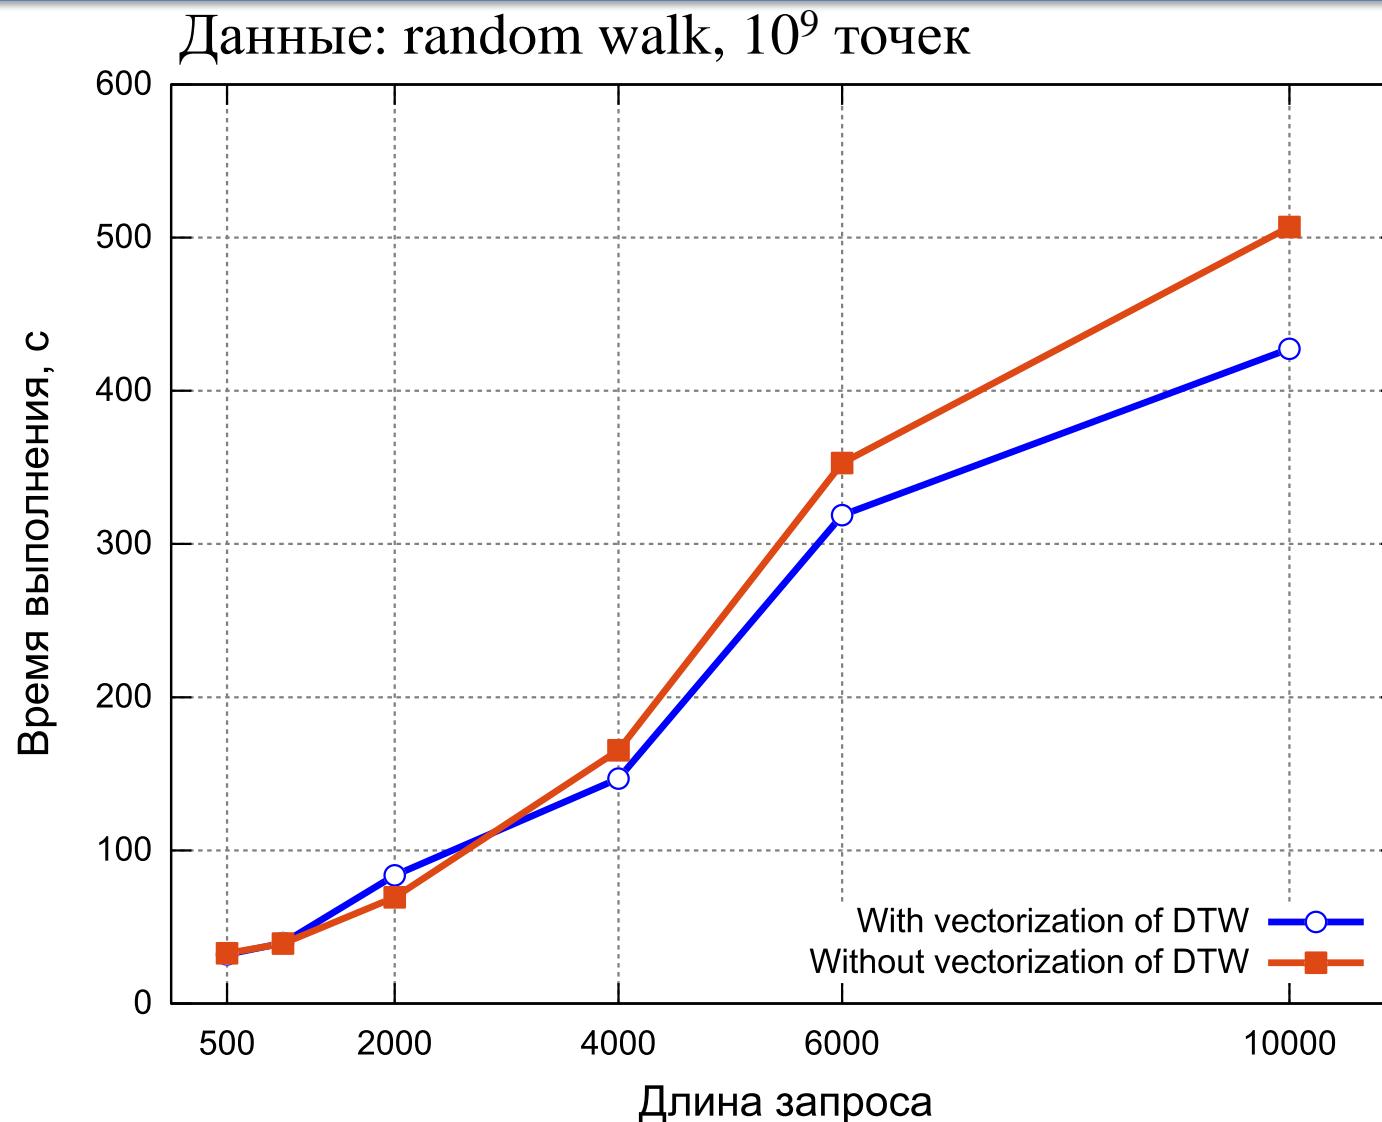
Эксперименты: утилизация Phi



Эксперименты: длина очереди



Эксперименты: векторизация



Заключение

- ❑ Новый параллельный алгоритм поиска похожих подпоследовательностей временного ряда для сопроцессоров Intel Xeon Phi.
- ❑ Эксперименты: высокая эффективность алгоритма при большой длине запроса.
- ❑ Будущие исследования: кластерная система с узлами на базе сопроцессоров Intel Xeon Phi.

- ❑ Спасибо за внимание
 - Вопросы?
 - Михаил Леонидович Цымблер
mzym@susu.ru