

# Быстрое распознавание повторов в генетических последовательностях на основе спектрально- аналитического метода

Панкратов А.Н., Пятков М.И., Руднев В.Р., Куликова Л.И.

Институт математических проблем биологии РАН

# Виды повторов

## Тандемные



...CGAGCATGGACTTTTGAGCAC...TTTGAGCAC...CACGAGCCACGGA...

## Разнесенные



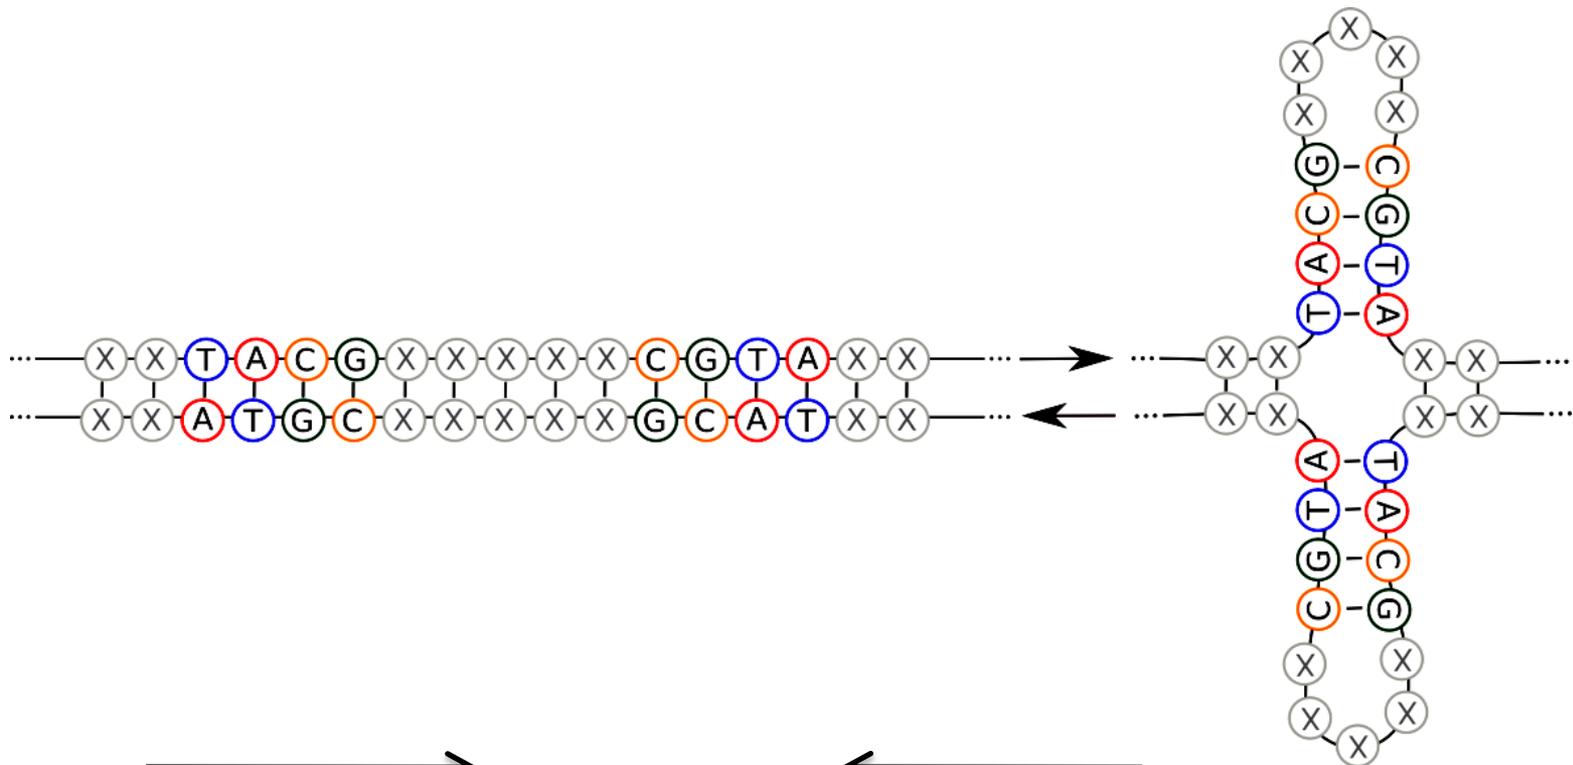
...CGAGCATTTGAGCAC...TGGACTTTCACGAGCCACTTTGAGCAC...GGA...

## Инвертированные



...CGAGCATTTGAGCAC...TGGACTTTCACGAGCCAC...GTGCTCAAAGGA...

# Инвертированные повторы



...TACG.....CGTA...

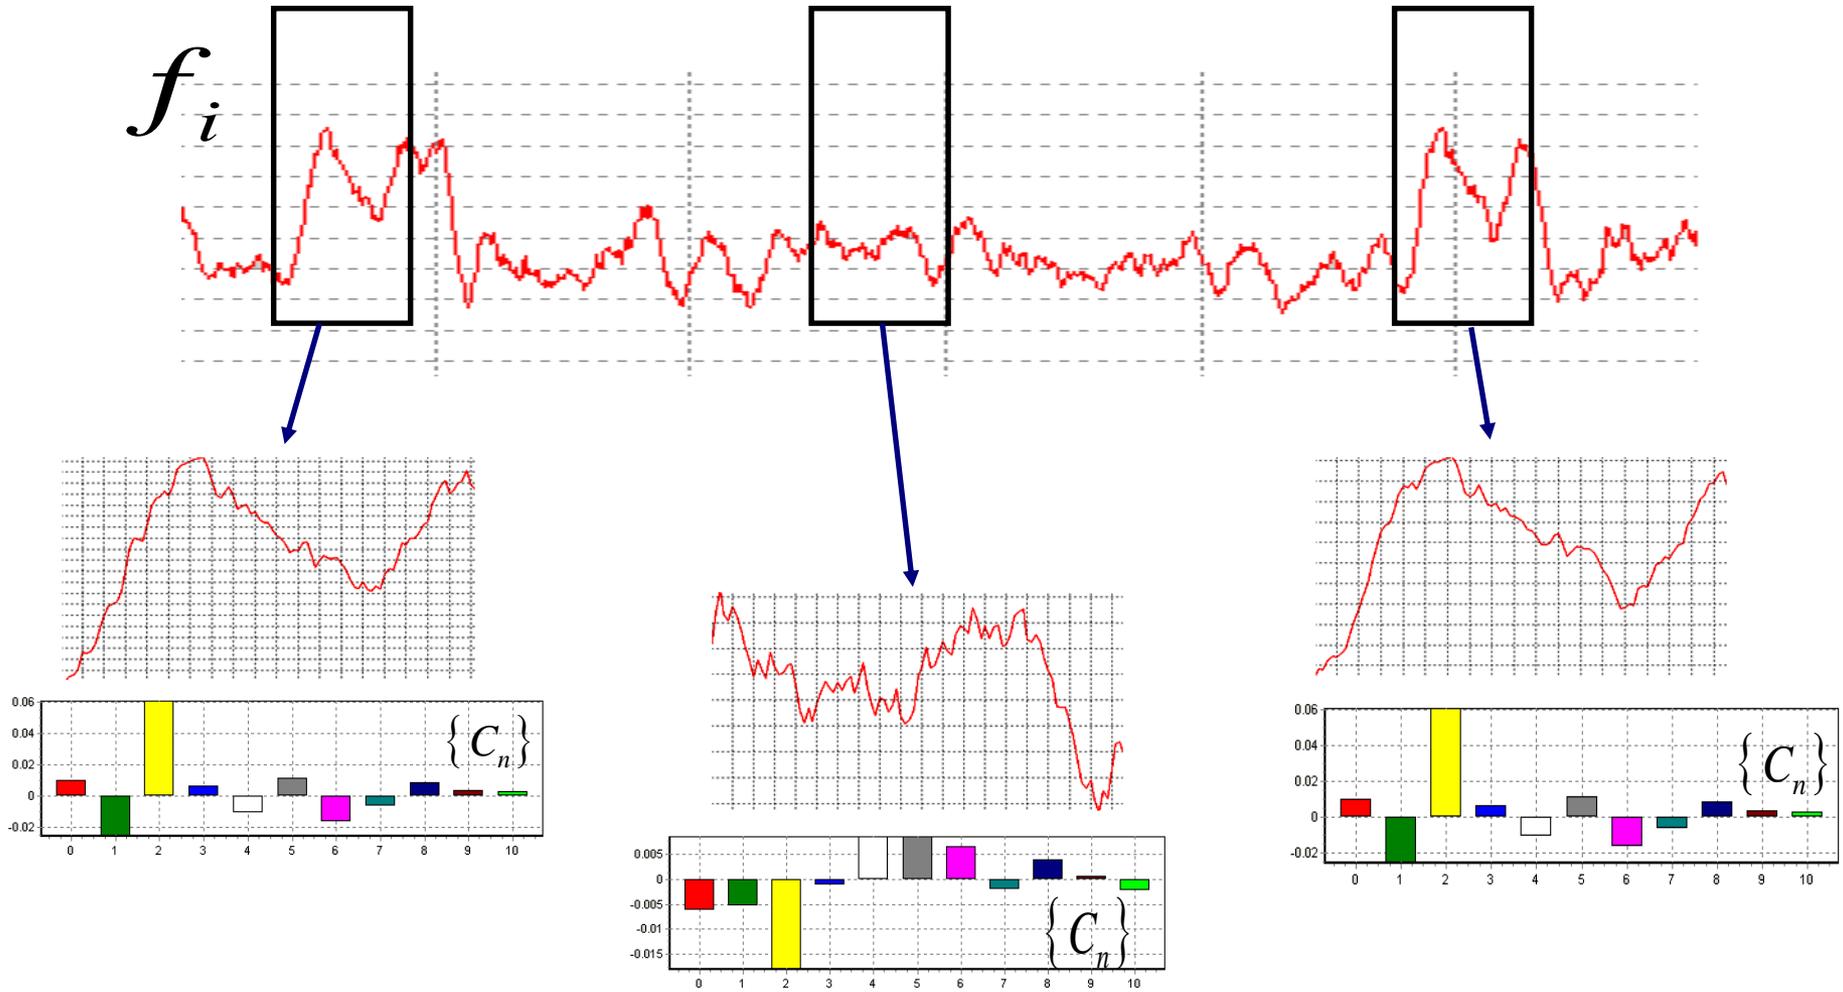
комплементарный

# Проблемы поиска повторов

- Точечные мутации
- Протяженные повторы ( $\geq 2000$ )
- Большая длина исследуемых последовательностей ( $10^6$ - $10^9$  нуклеотидов)

Гипотеза: методы из области обработки сигналов могут подойти лучше для поиска неточных протяженных последовательностей

# Основная идея алгоритма

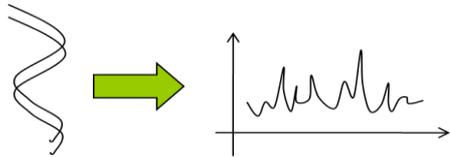


Ф.Ф.Дедус, Л.И.Куликова, С.А.Махортых, Н.Н.Назипова, А.Н.Панкратов, Р.К.Тетуев.  
Аналитические методы распознавания повторяющихся структур в геномах. ДАН, 2006,  
т. 411, №5, 1-46.

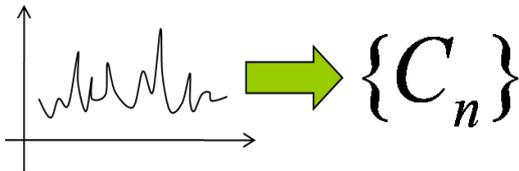
# Общая схема работы алгоритма

actg**NNN**tgca  
→ actgtgca

Предварительная обработка ДНК последовательностей: удаление N регионов, 4-х кратное сжатие



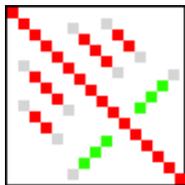
Получение эквивалентного функционального представления: GC%, GA% состав



Спектральное разложение (как минимум 10 –и кратное сжатие)

$$\theta(\{C_n\}, \{C'_n\}) < \varepsilon$$

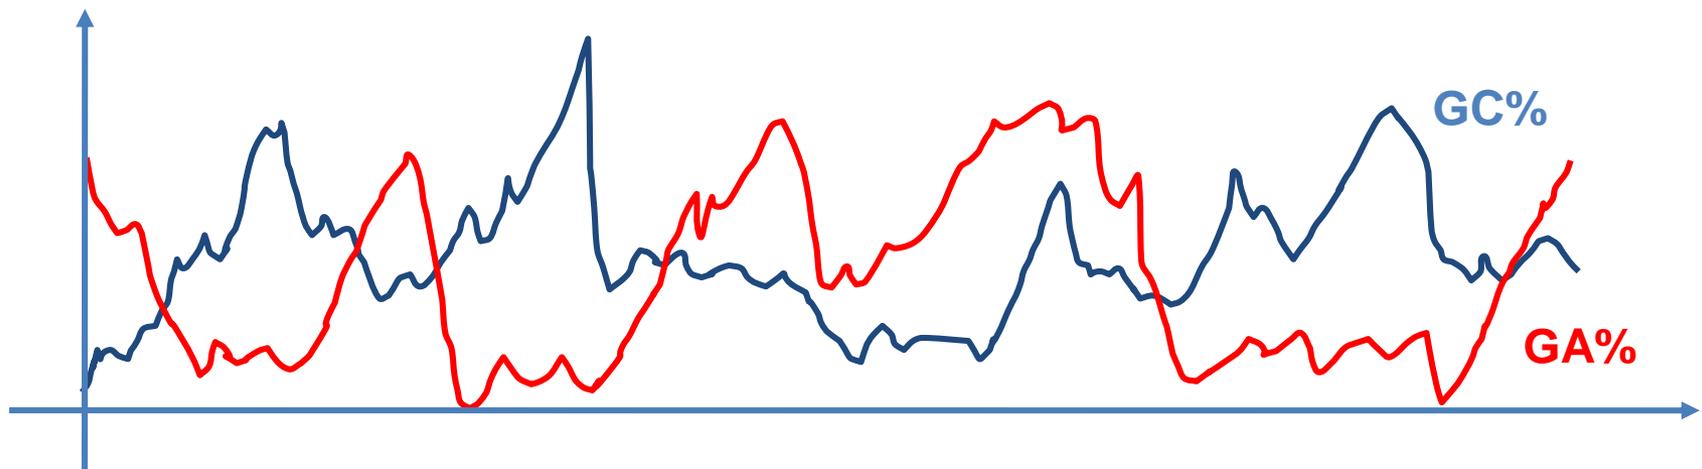
Сравнение спектров фрагментов ДНК-профилей



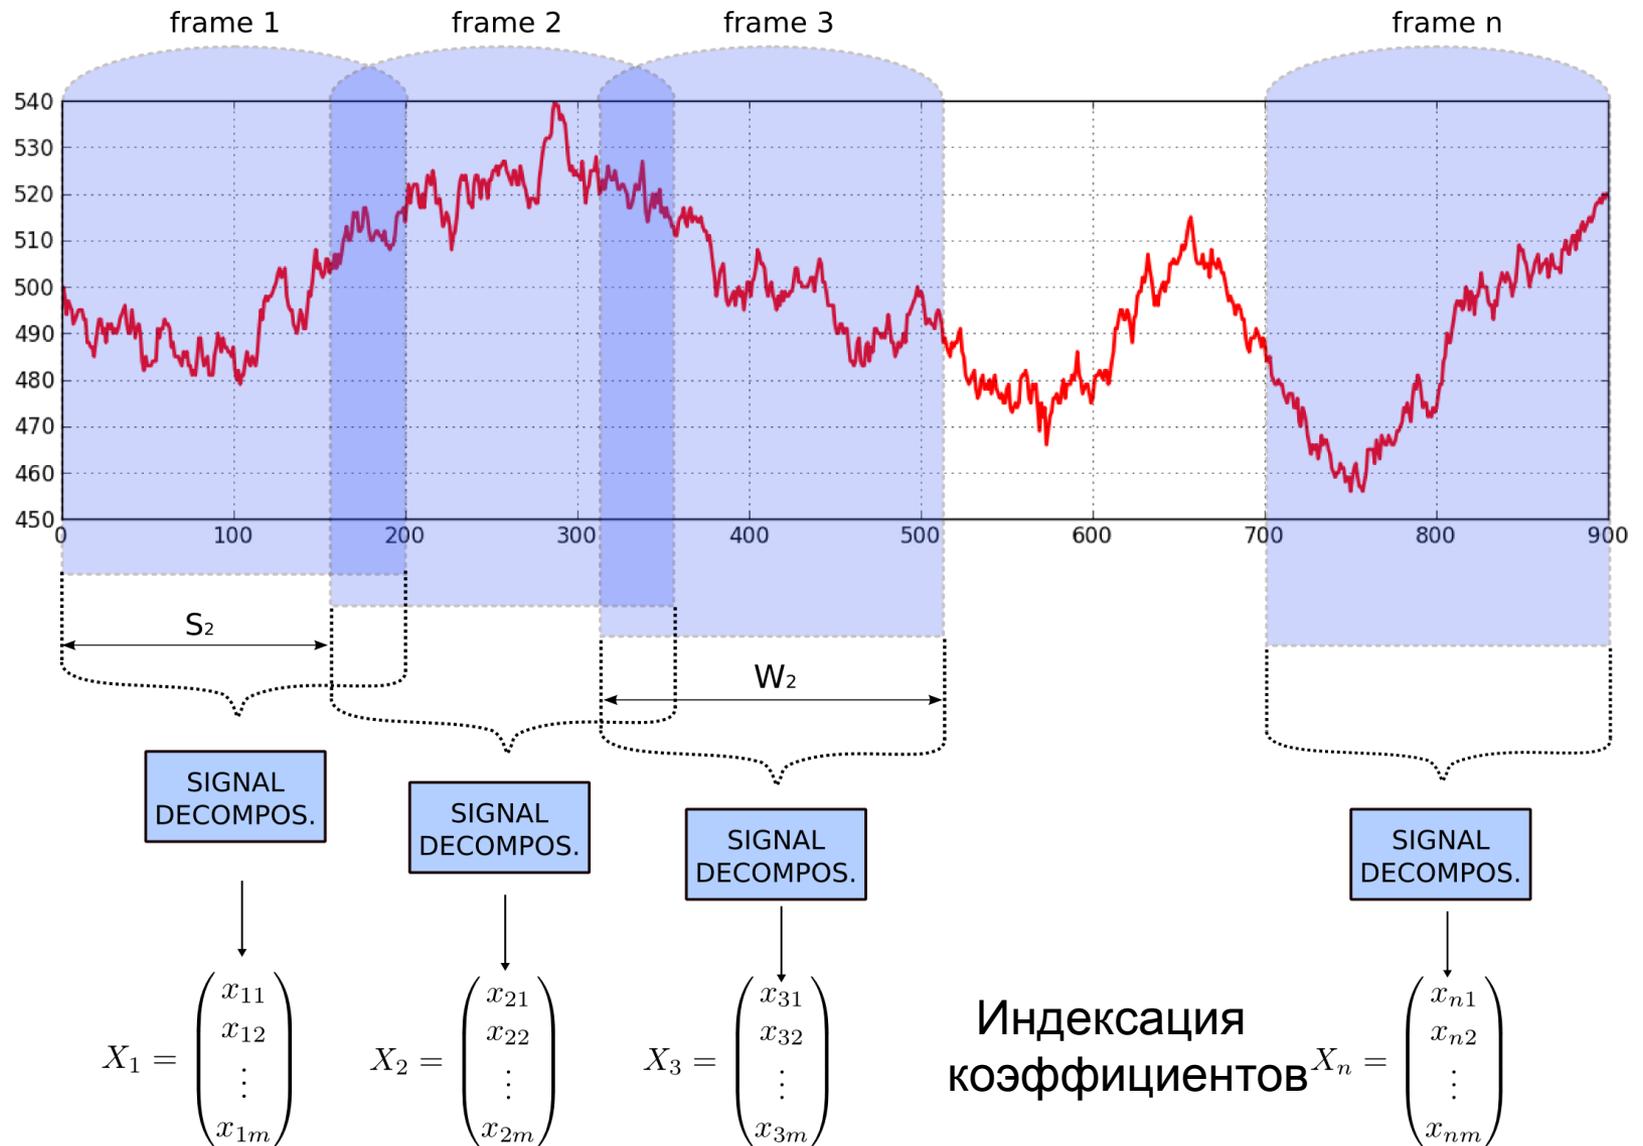
Отображение результатов на точечной матрице и их анализ

# Преобразование нуклеотидной последовательности в функциональное представление

Теорема: для однозначного восстановления символьной последовательности достаточно  $\lceil \log_2 N \rceil$  функций-аналогов, где  $N$  – мощность алфавита



# Преобразование функций-аналогов в спектры коэффициентов разложения



# Сравнение спектров

$$\rho^2(f, g) = (f - g, f - g) = \sum_{k=0}^{L-1} (A_k - B_k)^2 (\varphi_k, \varphi_k)$$

$$(f - g, f - g) = \int_{-\pi}^{\pi} (f - g)^2 dt \leq 2\pi W_1^2$$

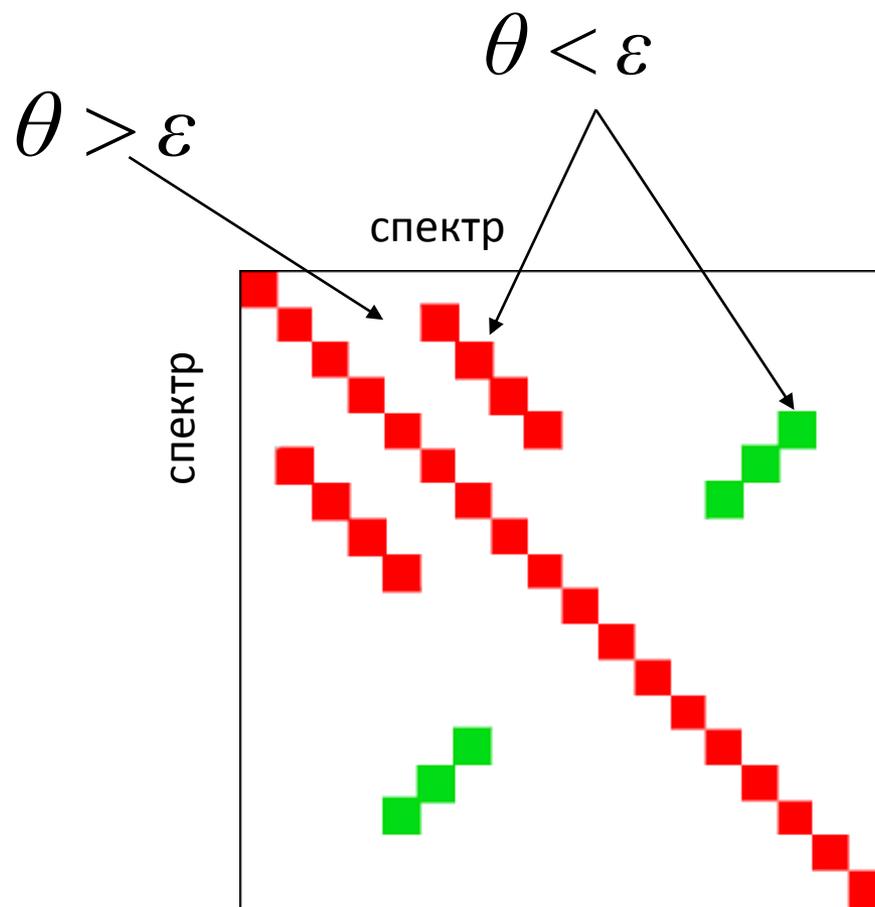
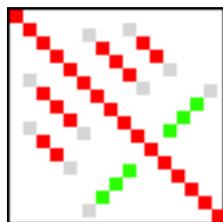
$$\theta(f, g) = \frac{1}{2W_1^2} \sum_{k=0}^{L-1} (A_k - B_k)^2 \leq \varepsilon \leq 1$$

$$\theta(\{A_n\}, \{B_n\}) < \varepsilon$$

Метрика:

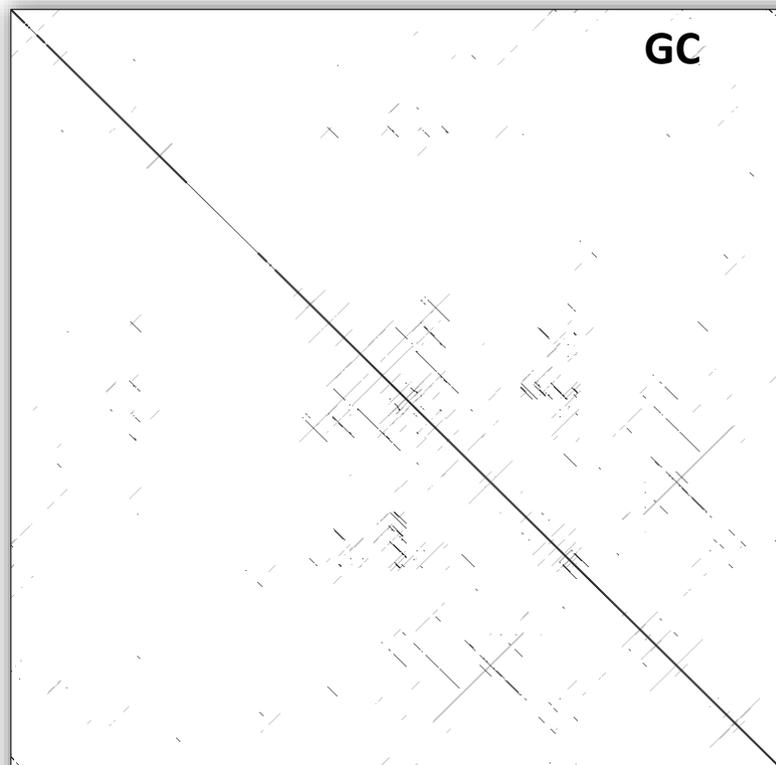
- 1) монотонна по числу коэффициентов,
- 2) нормирована
- 3) инвариантна к масштабу

# Отображение результатов на матрице спектральной схожести

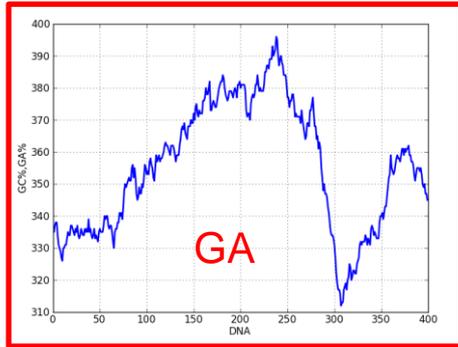


Автоматический поиск заданных образцов

# Фильтрация



$$(\theta(f^{GC}, g^{GC}) \leq \varepsilon) \wedge (\theta(f^{GA}, g^{GA}) \leq \varepsilon)$$



$$\begin{cases} C_{2k}^{GA} = C_{2k}^{GArev} \\ C_{2k+1}^{GA} = -C_{2k+1}^{GArev} \end{cases}$$



$$\begin{aligned} C_0^{CT} &= \sqrt{2}W_1 - C_0^{GA} \\ C_n^{CT} &= -C_n^{GA} \end{aligned}$$



$$C_0^{CT} = \sqrt{2}W_1 - C_0^{GA}$$

$$\begin{cases} C_{2k}^{CT} = -C_{2k}^{GA} \\ C_{2k+1}^{CT} = C_{2k+1}^{GA} \end{cases}$$

# Сложность алгоритма:

Матрица фиксированного размера строится за линейное время относительно длины последовательности ***n***

$$An + Bn + Cn^2$$

без пропорционального масштабирования параметров  $W_2$  и  $S_2$

$$An + Bn + c$$

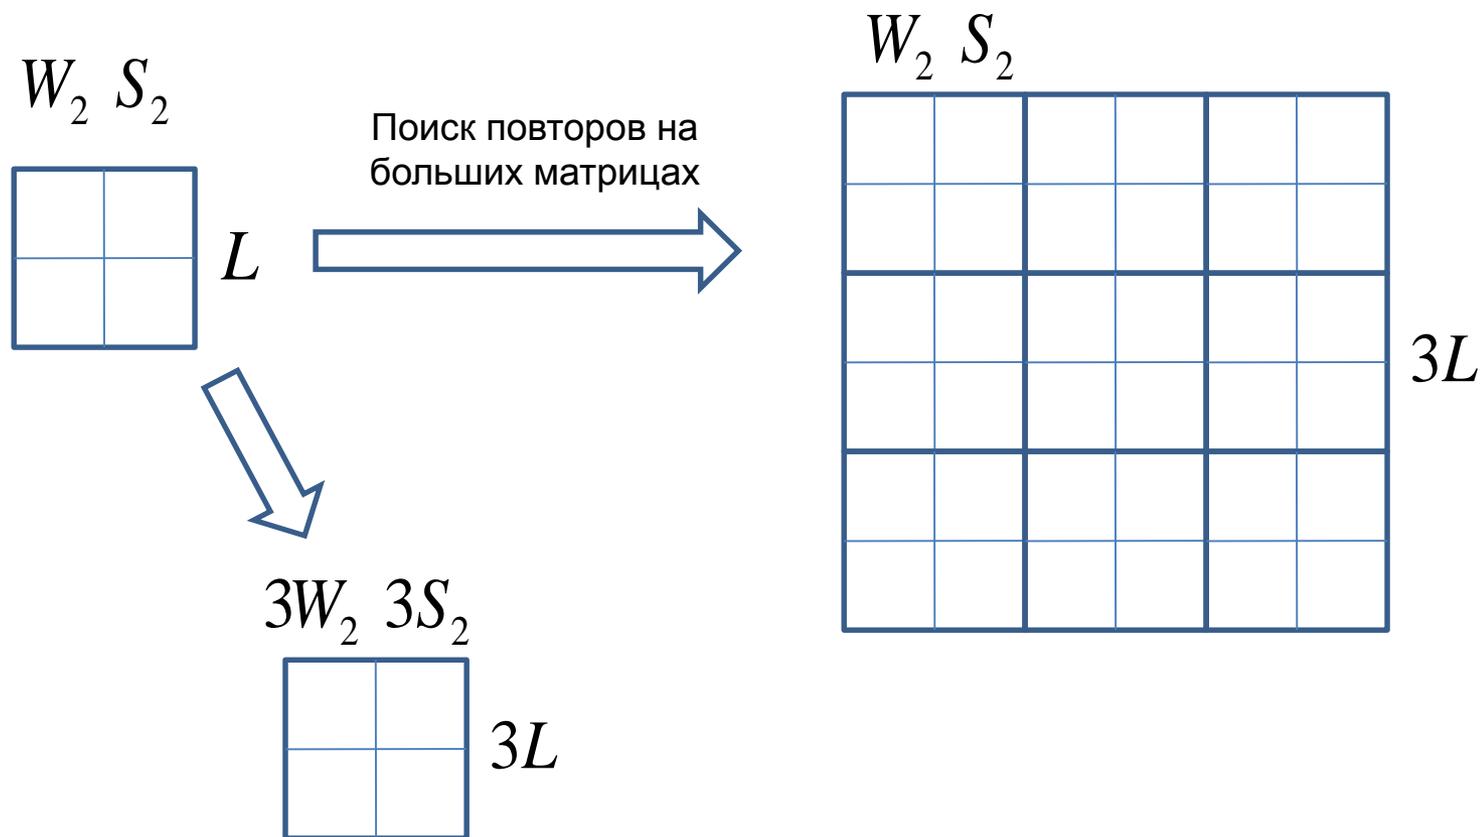
с масштабированием

$An$  - вычисление кривых GC,GA содержания

$Bn$  - вычисление векторов коэффициентов разложения

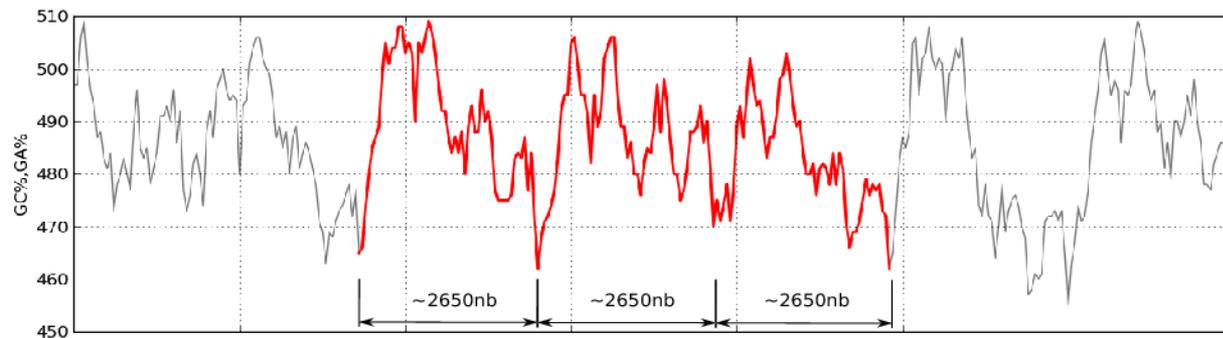
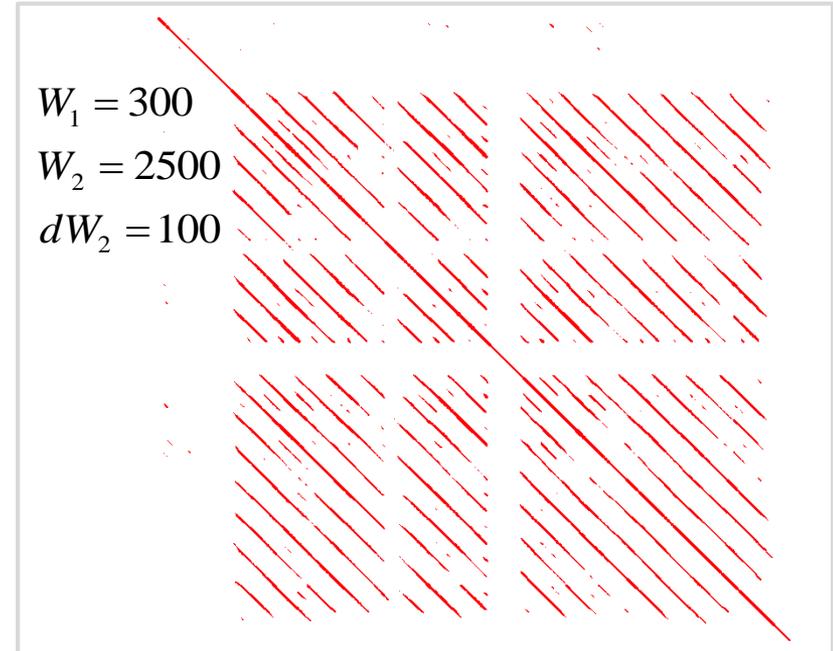
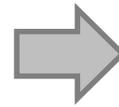
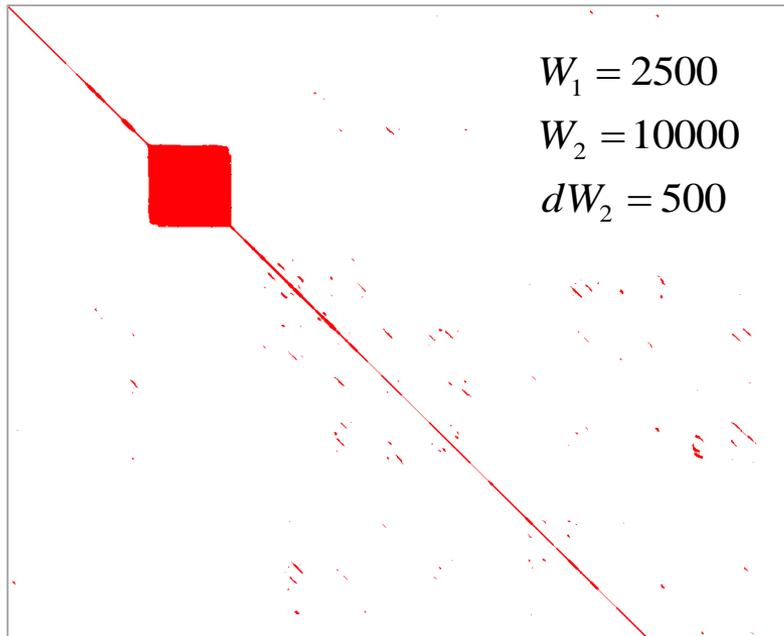
$Cn$  - сравнение векторов коэффициентов

# Оптимизация спектрального метода



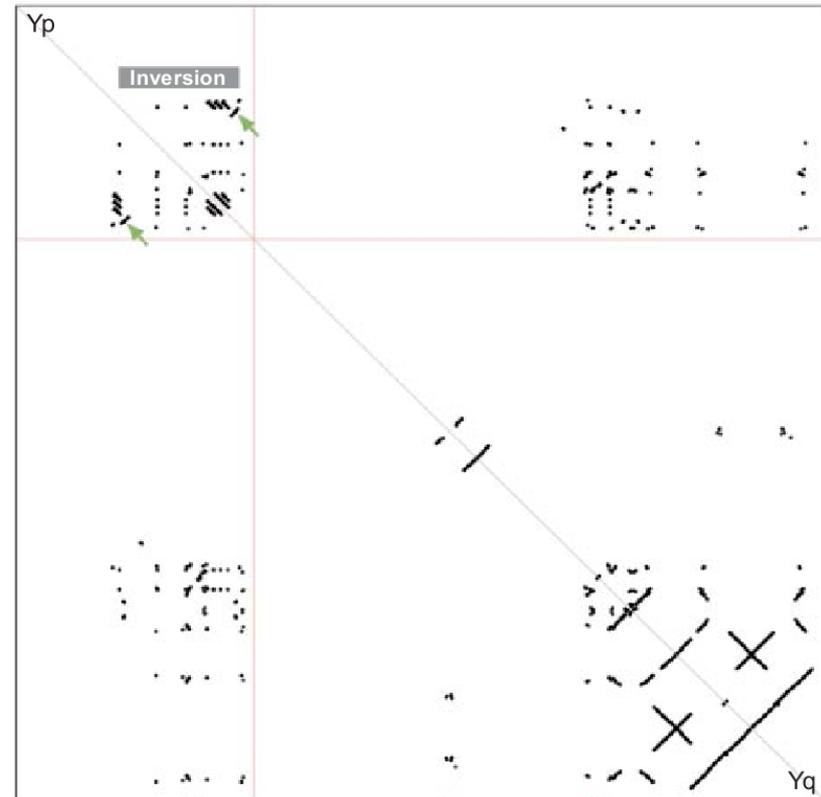
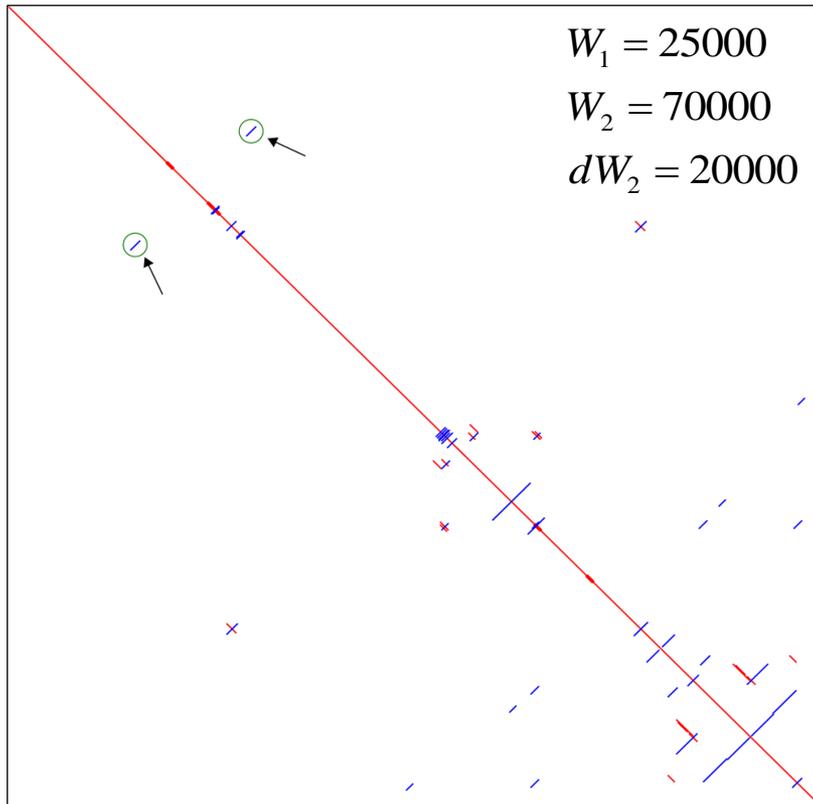
Integrated Performance Primitives (Intel IPP) – векторизация  
Open Multi-Processing (OpenMP) – многопоточность

# Тандемный повтор (MSU1)



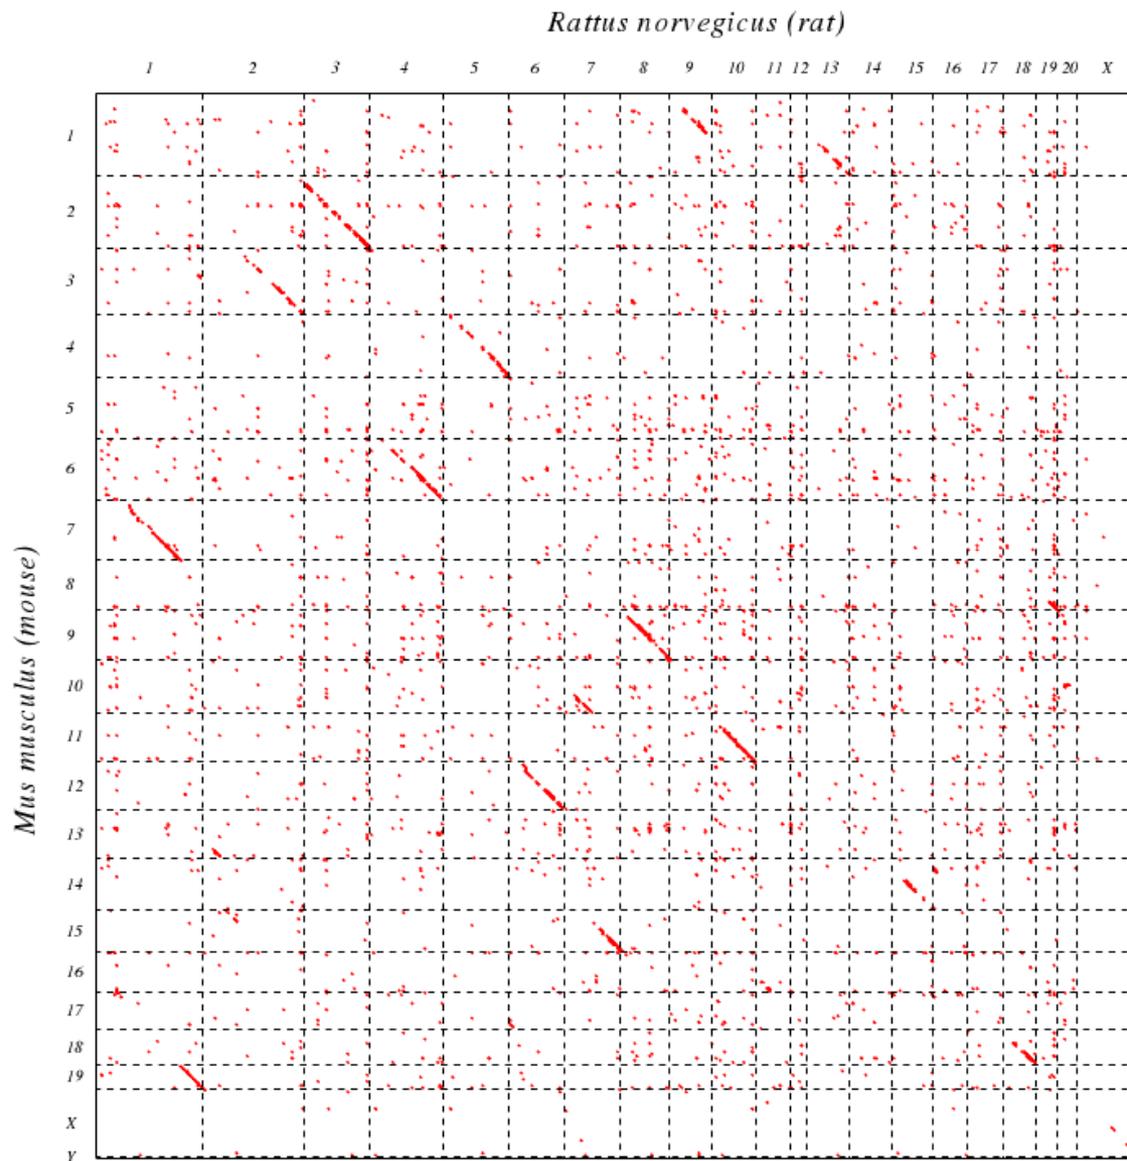
Pyatkov M.I., Filippov V.V., Pankratov A.N. Consensus of repeated region of rabbit chromosome 17 containing over 15 huge approximate tandem repeats. Repbase Reports. 2012. Vol.12, No.3.

# Y хромосома человека

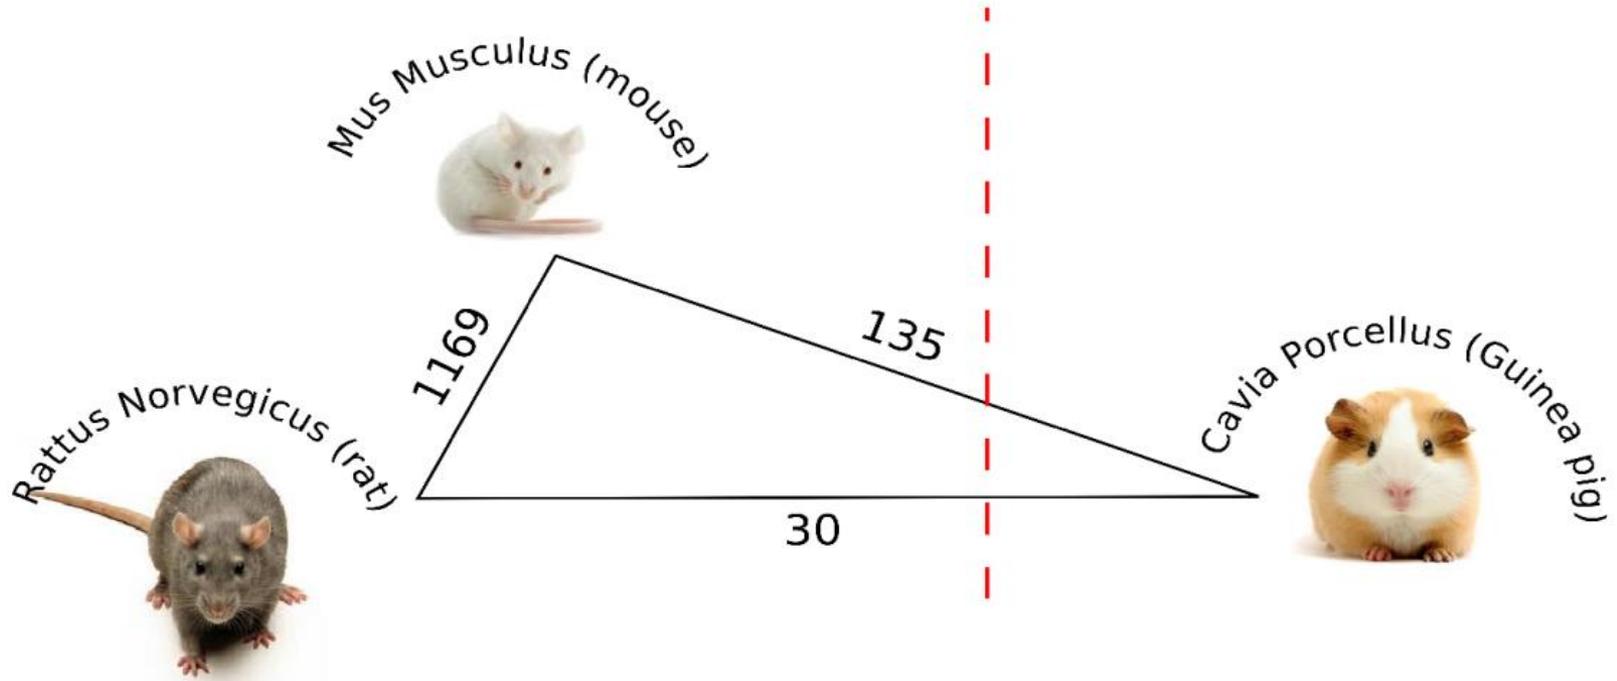


Tilford CA et al, A physical map of the human Y chromosome. Nature. 2001. No. 409, P.943--945

# Карта сравнения геномов мыши и крысы

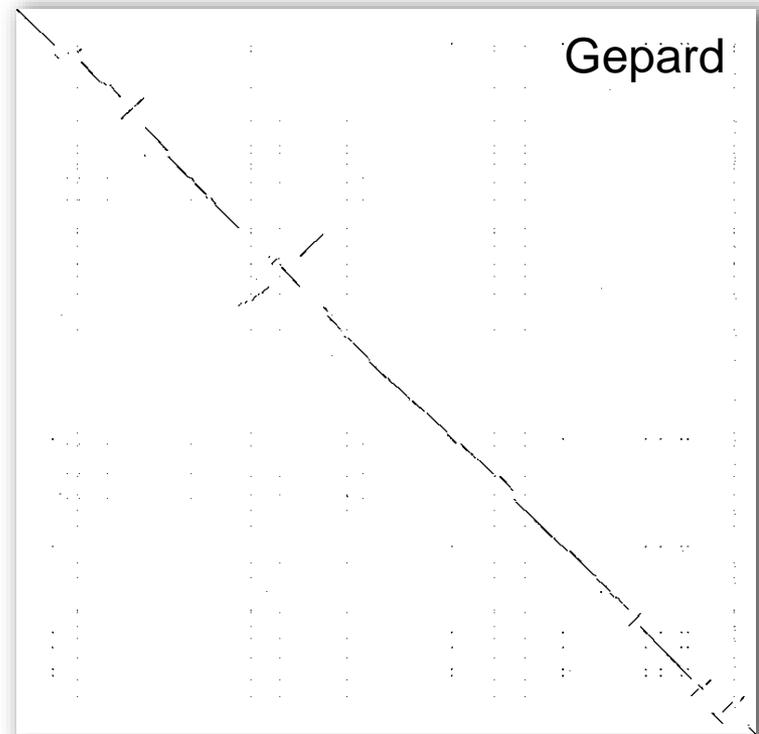
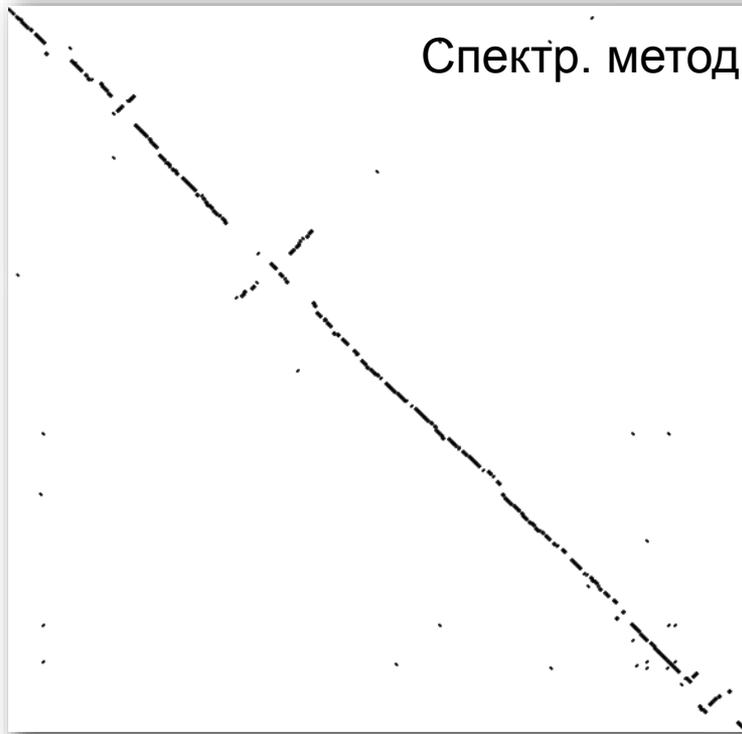


# Сравнение геномов



# Escherihia coli K12

Shigella flexnerу 2a

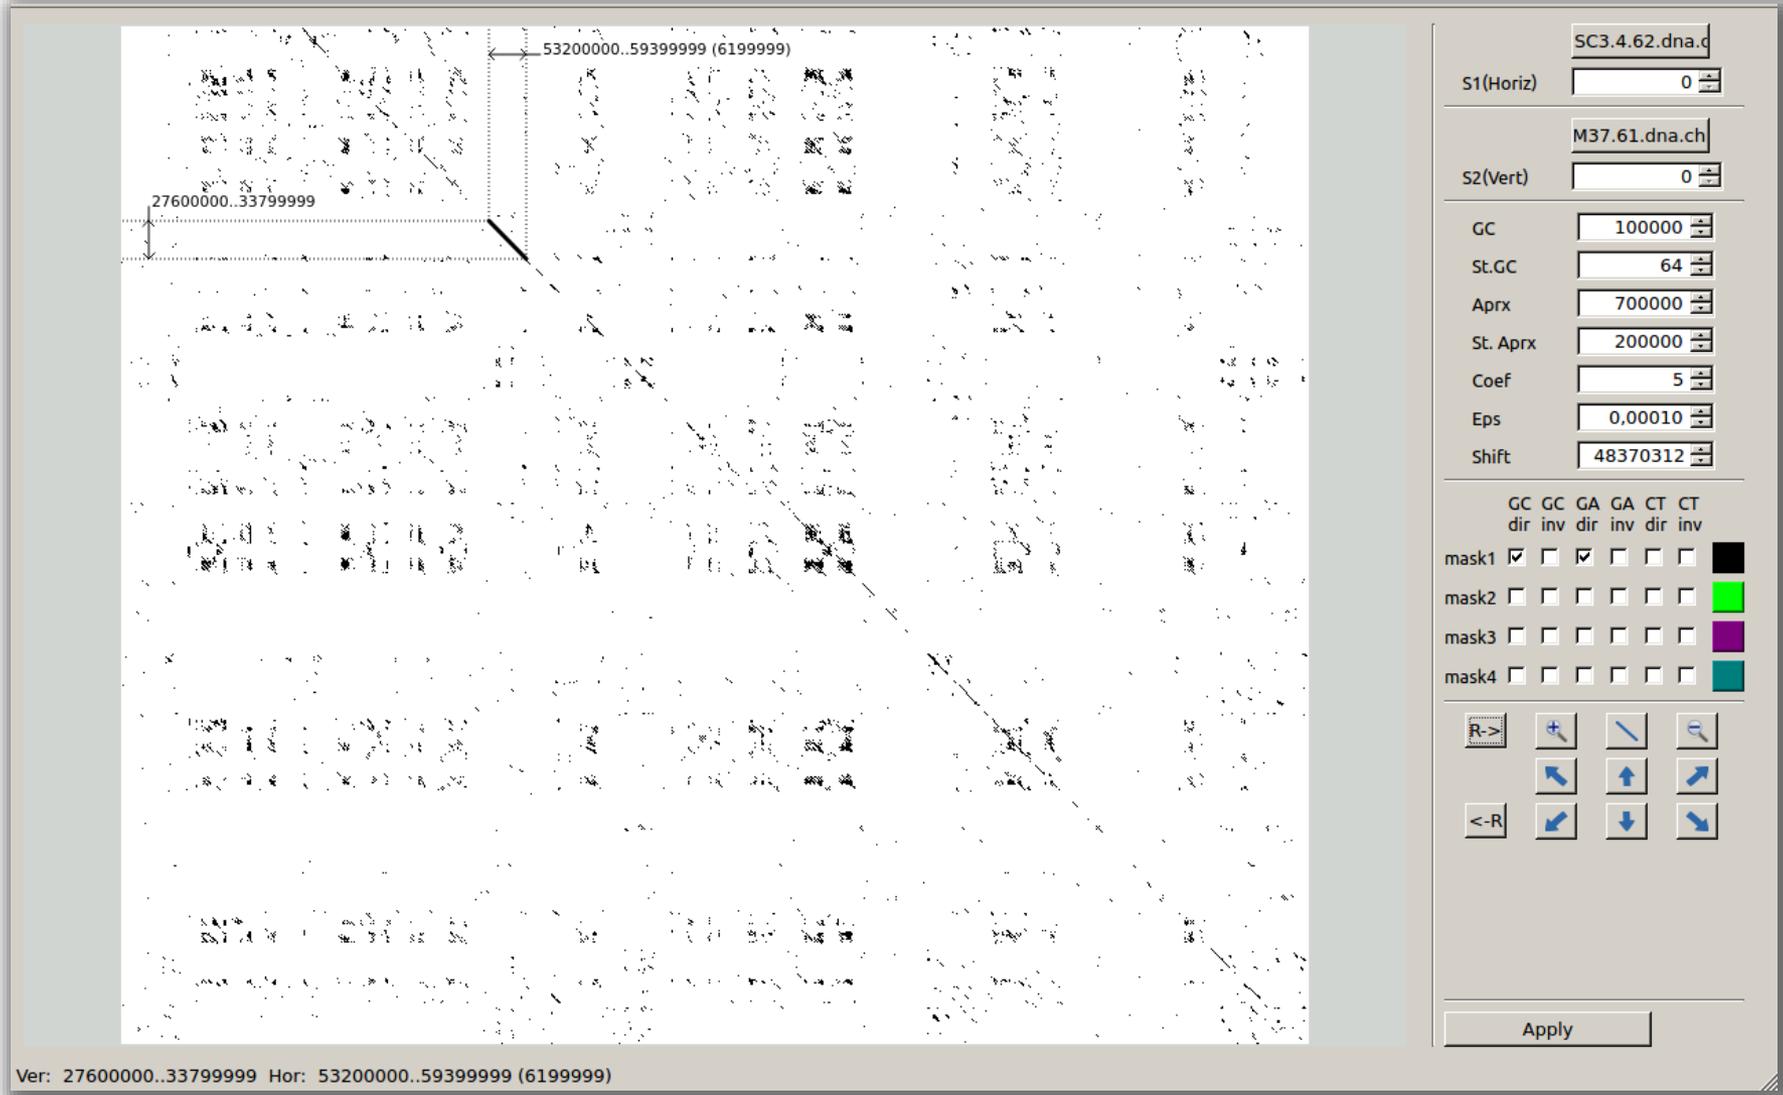


Длина ~ 5.000.000 н.п.

Krumsiek J., Arnold R., Rattei T. Gepard: a rapid and sensitive tool for creating dotplots on genome scale // **Bioinformatics**. 2007. Apr. Vol. 23, 8. P. 1026-1028.

Длина последовательности	Gepard	Спектр. метод
100000 н.п.	< 1 сек	< 1 сек
1000000 н.п.	< 5 сек	< 3 сек
5000000 н.п.	45 сек	< 14 сек
Y chr (2900000 н.п.)	5 мин	27 сек

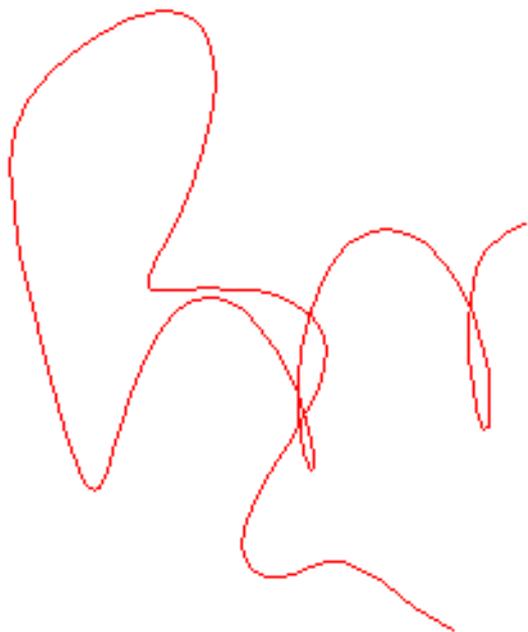
# S.B.A.R.S (Spectral Based Approach for Repeats Search)



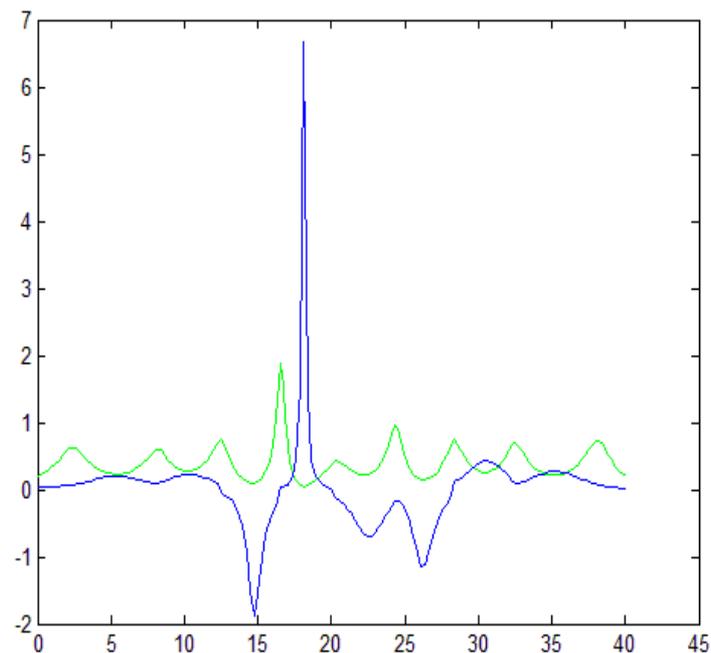
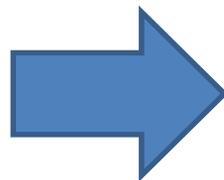
Pyatkov M. I., Pankratov A. N. (2014) SBARS: fast creation of dotplots for DNA sequences on different scales using GA,GC-content // Bioinformatics, Vol. 30, No. 14, pp. 1765 - 1766

# Реализация алгоритма поиска паттерна а-а уголка в белках

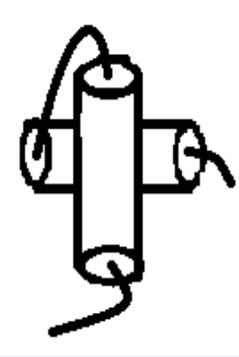
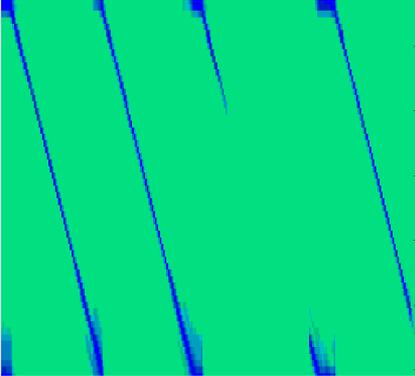
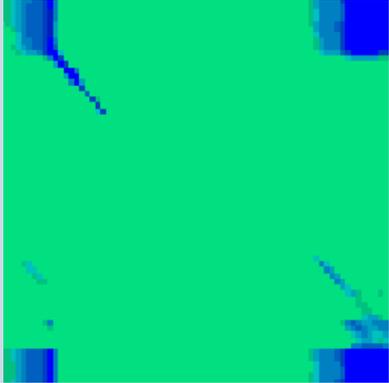
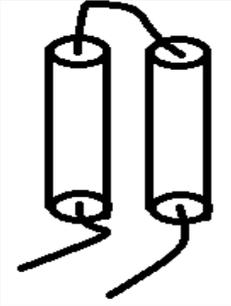
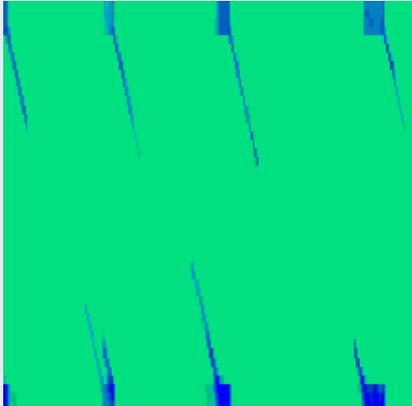
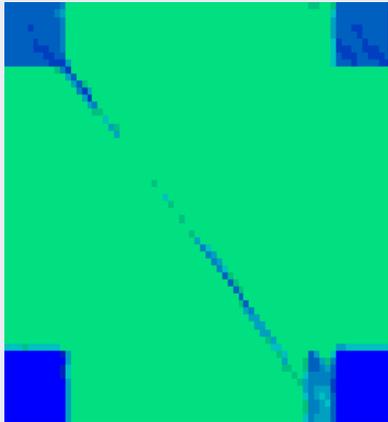
Паттерн – 1D1L.pdb{15 - 37}



Получение  
кривых



# Сравнение пространственных структур белков

	1R69 (3 уголка)	1ROP (1 шпилька)
1D1L 		
256B 		

# Выводы

Разработан новый метод распознавания близких по структуре элементов геномов и пространственных структур белков

1. Распознавание повторов на разных масштабах
2. Выравнивание последовательностей или структур
3. Быстрое построение точечной матрицы

Благодарю за внимание!