

Институт проблем передачи информации
РАН (<http://www.iitp.ru>)

Лаборатория математических методов и
моделей в биоинформатике
(<http://lab6.iitp.ru>)

д.ф.-м.н. проф. зав лаб
Любецкий Василий Александрович
(lyubetsk@iitp.ru)

С 2000 года нами опубликовано:

2 монографии и 1 вузовский учебник (по математике)

и

23 статьи в математических журналах

(Успехи мат. наук, Труды института им. Стеклова,

Мат. Заметки и т.д.)

А также – опубликовано 36 статей в биологических и информатических журналах (Молекулярная биология, Биофизика, Биохимия, FEMC, ВМС, JVBCB, inSB, ...)

Подготовлено 2 докторские и 3 кандидатские диссертации (все – физ.-мат. науки, «теоретические основы информатики», «биоинформатика»)

Ежегодно наши аспиранты и сотрудники делают доклады примерно на 4-х международных конференциях (математических, биологических, информатических)

За это время аспиранты и сотрудники приняли участие в выполнении: 25 грантов, 2 целевых грантов, 2 научных программ и 2 совместных тем по линии РАН-СНРС.

Лауреаты премии

«За лучшую публикацию в журнале Молекулярная биология» за 2005 год и премий некоторых зарубежных университетов

Тесно сотрудничаем с кафедрой «математической логики и теории алгоритмов» [Мех-мата МГУ](#), в частности, читаем там курс «Модели и алгоритмы в биоинформатике». Сотрудничаем с факультетом [биоинформатики и биоинженерии](#) МГУ, с факультетом [ВМК](#).

Регулярно ведем курсовые и дипломные работы, аспирантов. Сотрудничаем с аспирантурой Париж-7.
Включая оплачиваемую работу.

- 1) Проблемы эффективности;
- 2) Модели и алгоритмы основных молекулярных процессов в клетке: геномы бактерий, растений, водорослей и простейших

.....

ДНК=геном – последовательность в 4х-буквенном алфавите {A,C,T,G}

с характерной длиной 3 миллиона – 6 миллиардов позиций. Каждая буква называется «**нуклеотид**».

Данные

**Модели и алгоритмы
(компьютерный счет)**

Результат

лидерная область 2

лидерная область 3

ген 1

сигнал 2

ген 2

сигнал 3

ген 3



инструкция для
химической реакции –
создается фермент;
или для создания
другой молекулы:
белка или РНК

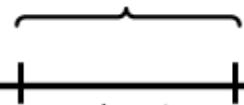
инструкция для
химической
реакции 2

инструкция для
химической
реакции 3

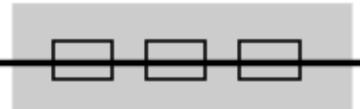
Ген считывается по сигналу из лидерной области!
Ген и сигнал эволюционируют!

Один из возможных типов сигналов (= регуляций):

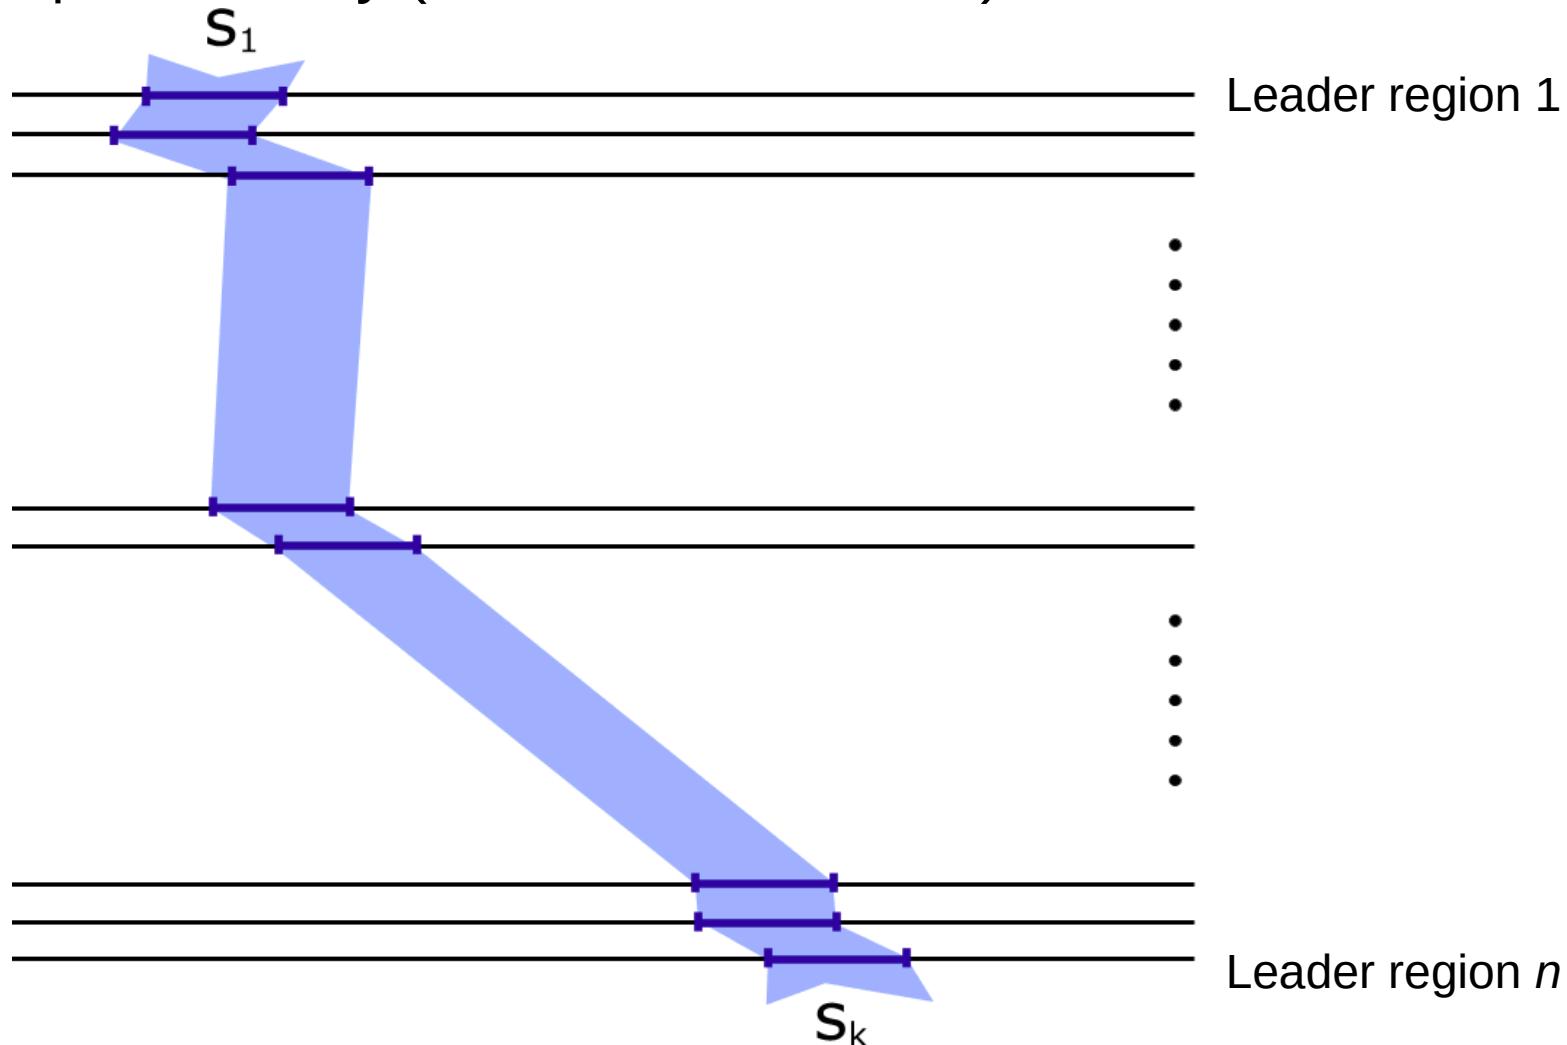
сайт посадки



репрессор/активатор



Даны n последовательностей. **Задача:** найти **систему сайтов (=сигнал, мотив)** $s = \{s_1, \dots, s_k\}$, состоящую из сайтов s_1, \dots, s_k , где $k \leq n$. Все сайты имеют одинаковую длину. **Определяем качество системы** как сумму попарных близостей сайтов, составляющих систему (=качество сигнала).

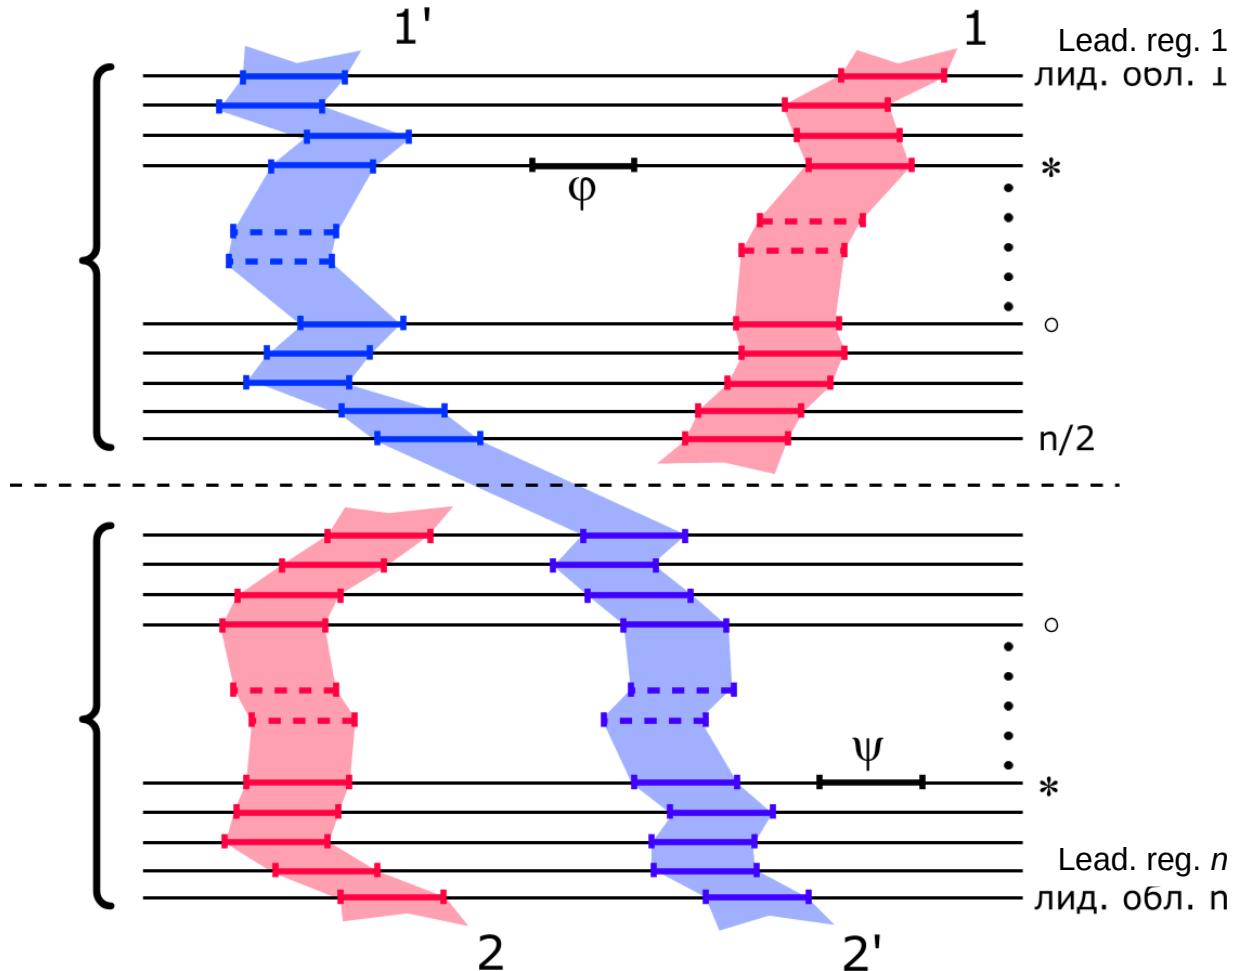


Ищем систему сайтов с максимальным значением качества, т.е. ищем минимум целевого функционала F в пространстве всех возможных систем:

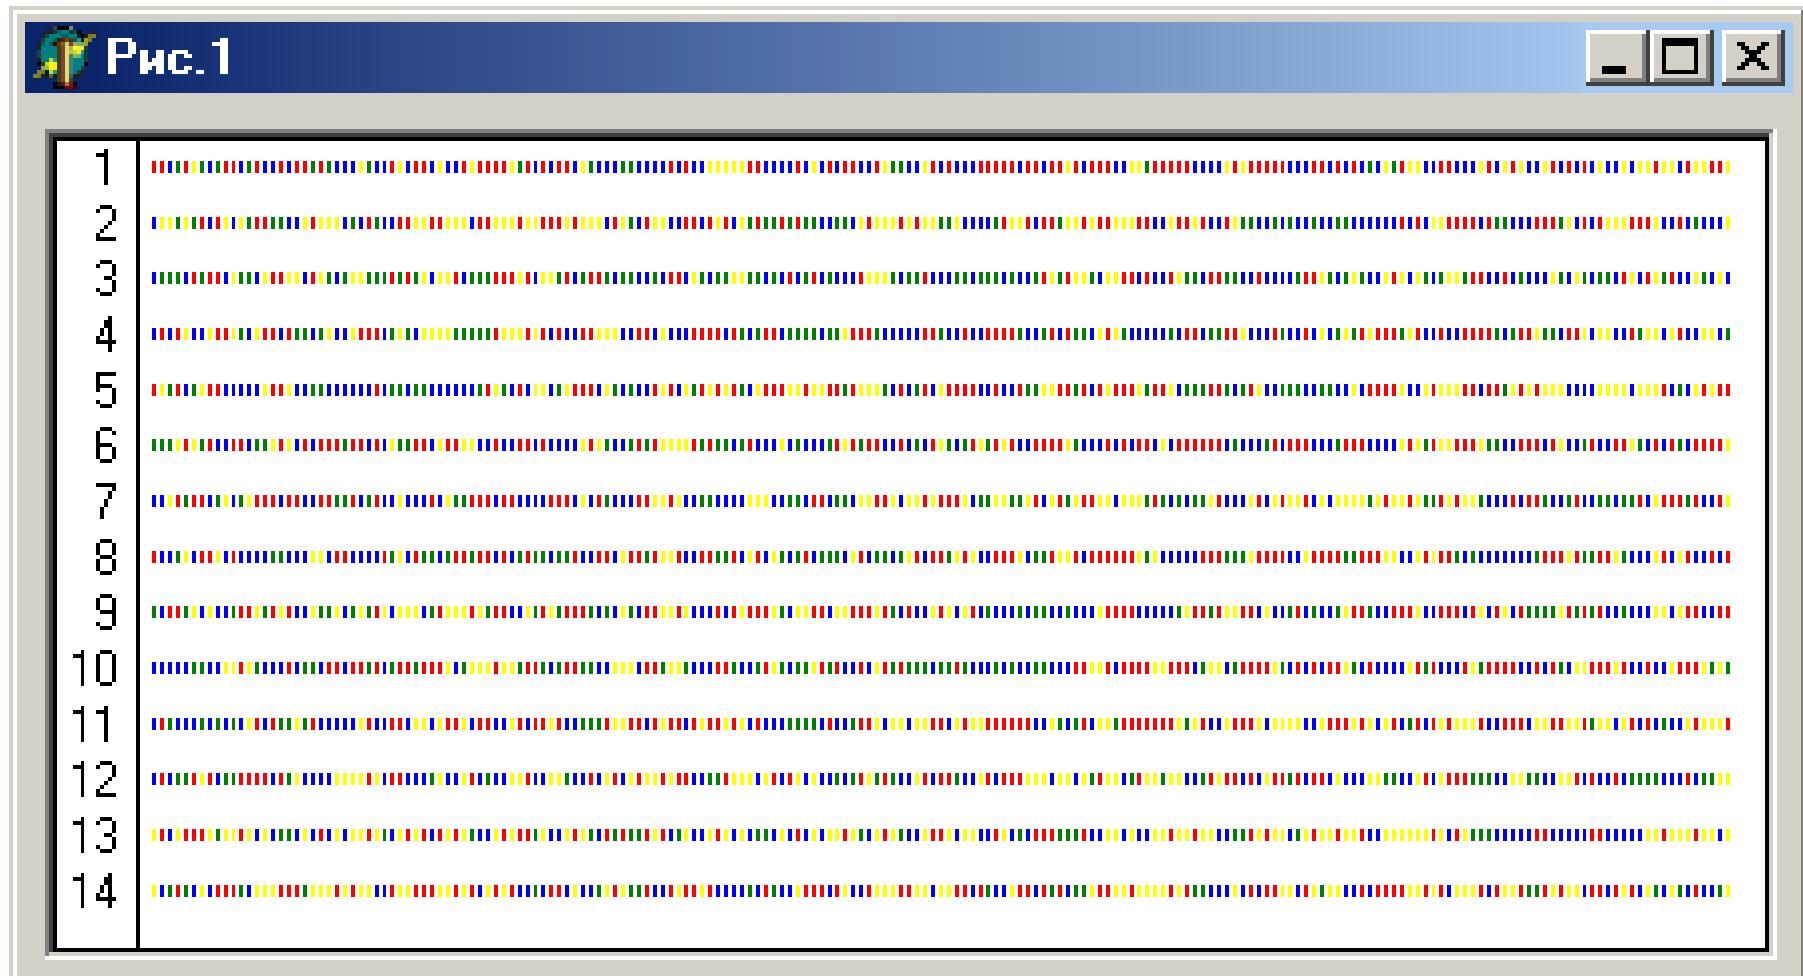
$$F(s = \{s_1, \dots, s_k\}) = \sum_{i,j=1}^k \rho(s_i, s_j)$$

Идея нашего алгоритма. Делим все последовательности на две примерно равные части и **лучшую** систему в одной части объединяем с **лучшей** системой в другой части. Пусть $\Gamma_1(\varphi)$ – **лучшая система** в одной части **как функция от** φ (и фиксирована последовательность *), а $\Gamma_2(\psi)$ – аналогичная система в другой части **как функция от** ψ .

Индуктивный шаг:
от $\Gamma_1(\bullet)$ и $\Gamma_2(\bullet)$
 переходим к $\Gamma(\bullet)$ по
 правилу: Γ лучшая
 система $\Gamma_1(\varphi)+\Gamma_2(\psi)$,
 полученная **пере-**
бором всех φ и ψ в
 *последователь-
 ностях



Пример. Даны $n=14$ последовательностей, каждая с длиной $t=201$; ищем систему сайтов с длиной 15



Работа алгоритма:

Рис.2

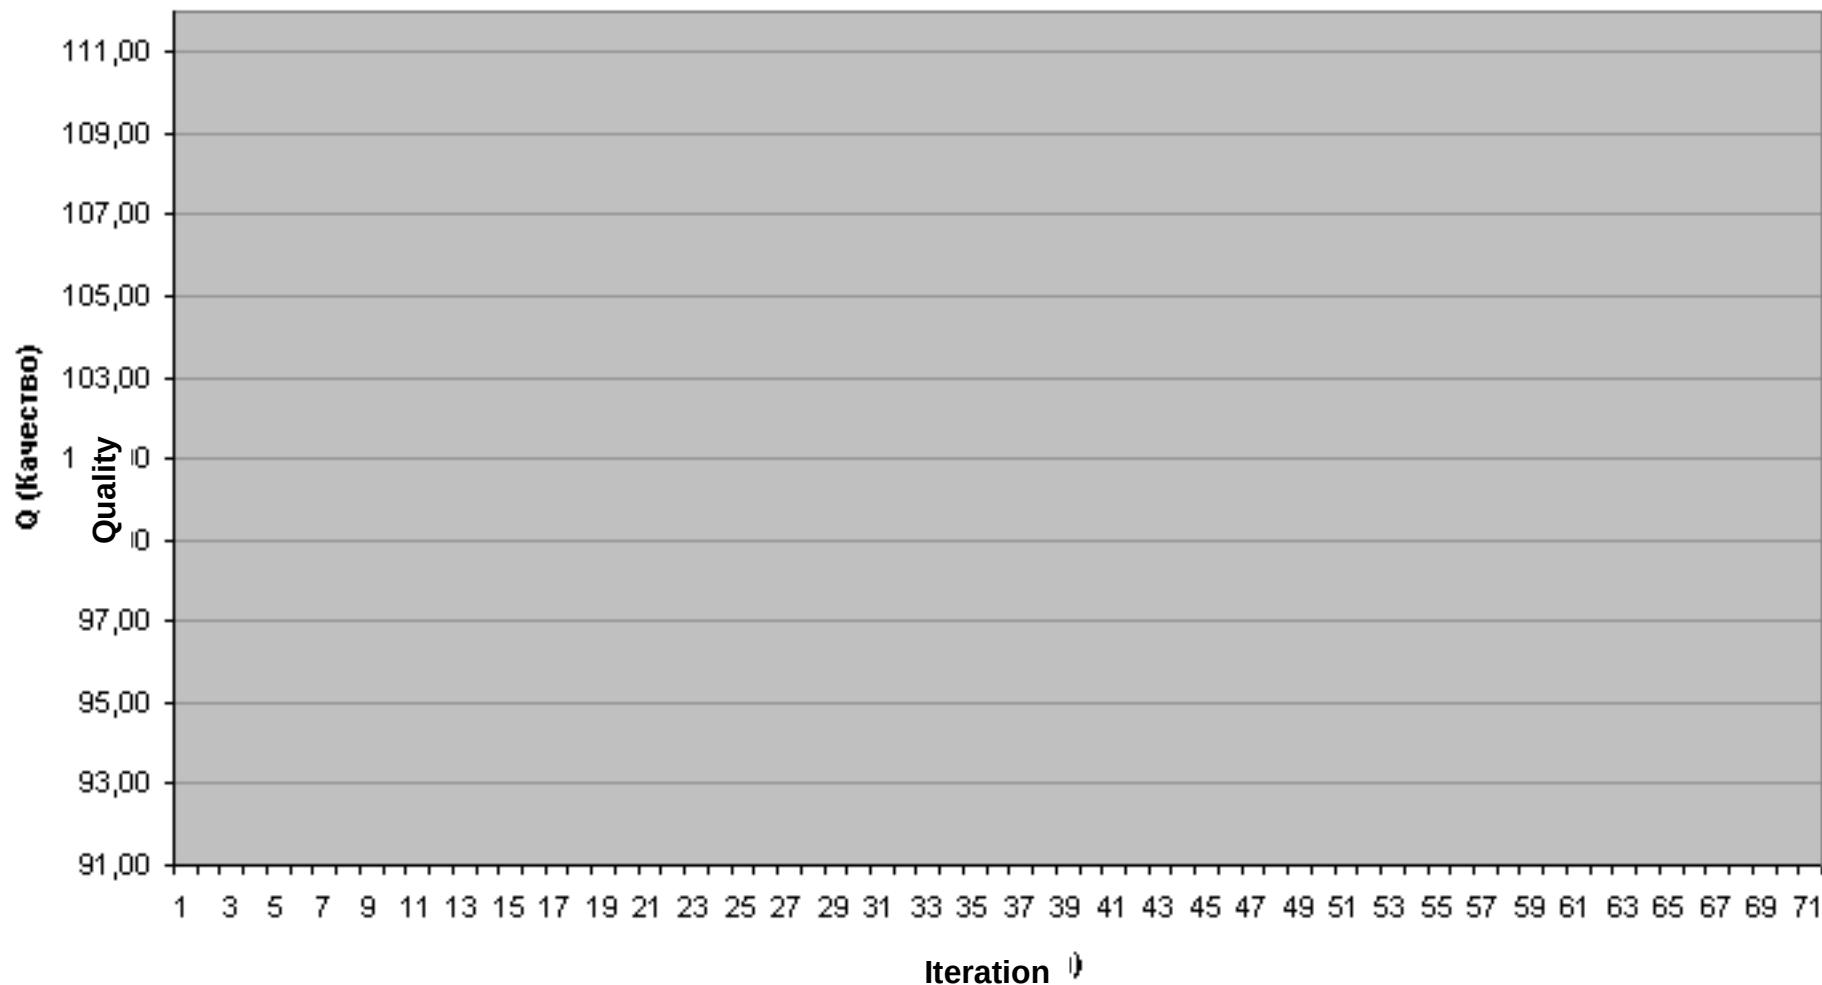
1	0	
2	0	
3	0	
4	0	
5	0	
6	0	
7	0	
8	0	
9	0	
10	0	
11	0	
12	0	
13	0	
14	0	

Результат работы алгоритма:

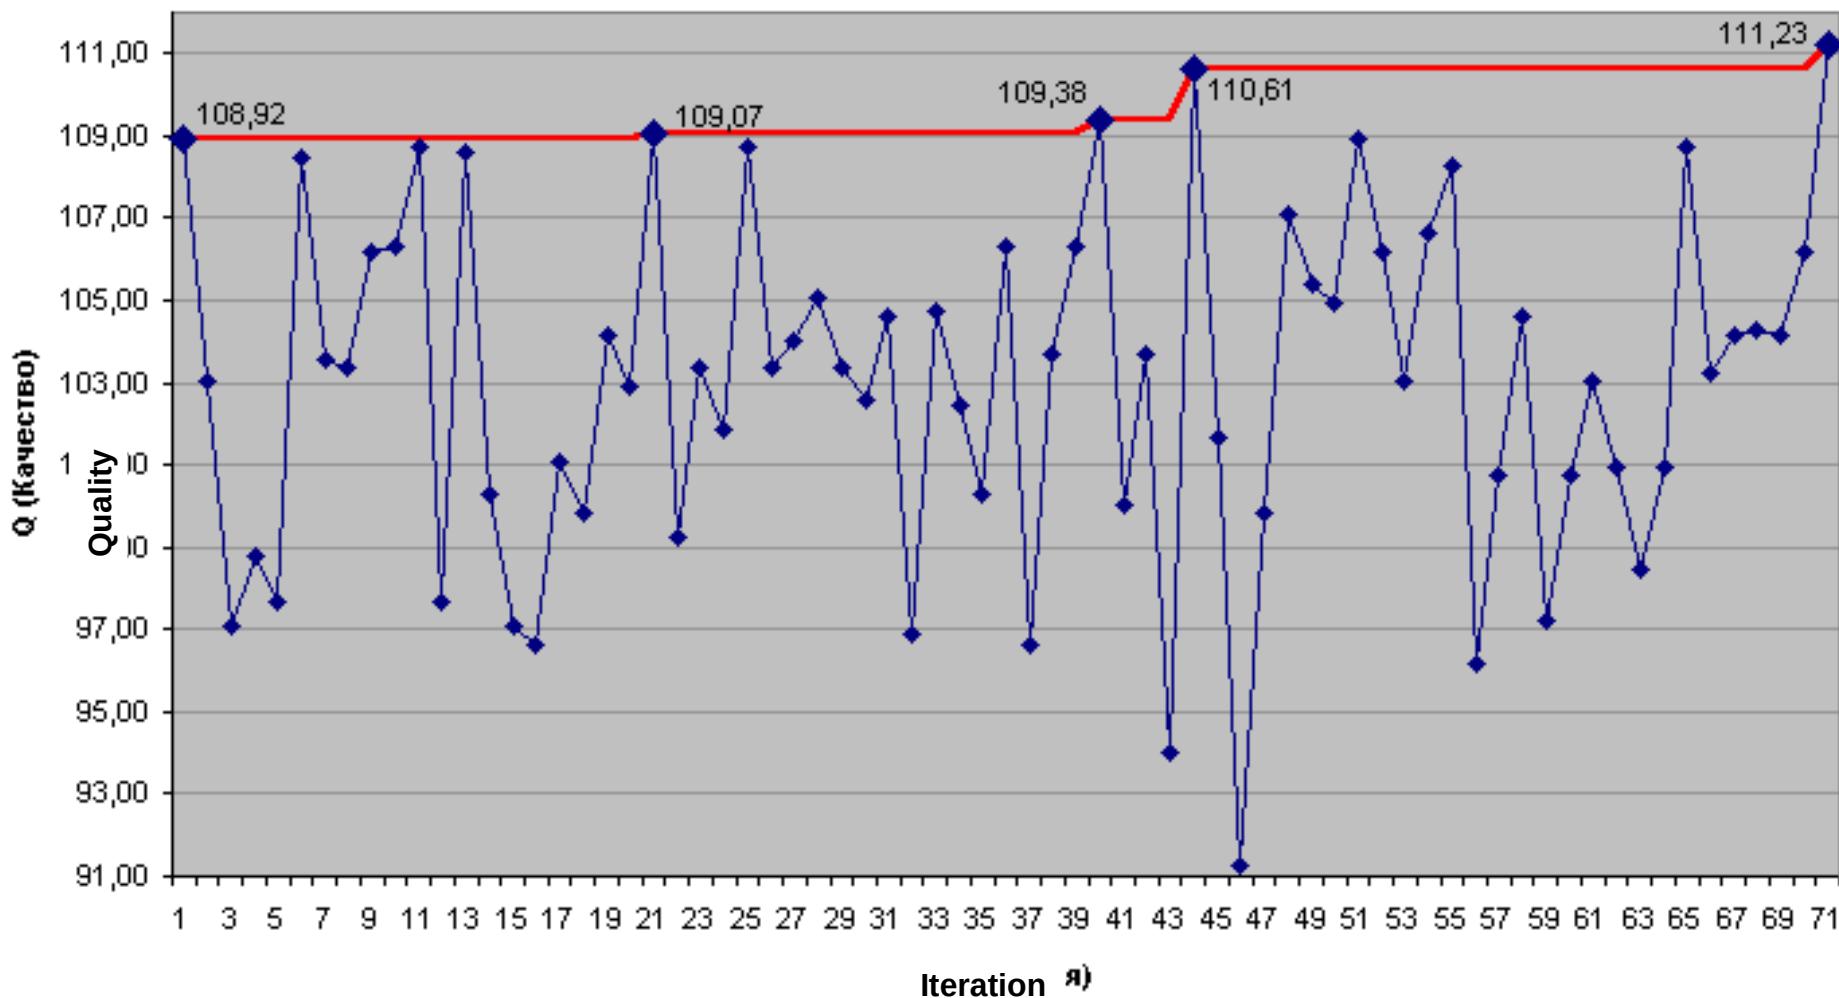
Рис.2

7	124	
13	123	
4	122	
12	121	
8	119	
2	117	
9	115	
10	115	
1	114	
5	114	
6	110	
14	110	
11	109	
3	103	

Качество потенциального сигнала растет в процессе счета:



Последовательное изменение качества сигнала в ходе алгоритма:



Параллельная реализация вычислительно трудоемких алгоритмов: поиск мультибоксового регуляторного сигнала в группе геномов

$P_0(0) \rightarrow$ 7734	$P_1(1) \rightarrow$ 9064	$P_2(2) \rightarrow$ 8872	$P_3(3) \rightarrow$ 11468	$P_4(4) \rightarrow$ 9314	$P_5(5) \rightarrow$ 8746	$P_6(6) \rightarrow$ 8696	$P_7(7) \rightarrow$ 9138	$P_8(59) \rightarrow$ 9622	$P_9(68) \rightarrow \dots$ 8106
$\downarrow Q_{0,0}(11)$ 9972	$\downarrow Q_{1,0}(12)$ 10654	$\downarrow Q_{2,0}(14)$ 10776	$\downarrow Q_{3,0}(13)$ 9310	$\downarrow Q_{4,0}(8)$ 8348	$\downarrow Q_{5,0}(10)$ 12150	$\downarrow Q_{6,0}(9)$ 11756	$\downarrow Q_{7,0}(15)$ 10018	$\downarrow Q_{8,0}(66)$ 9140	$\downarrow Q_{9,0}(75)$ 11472
$\downarrow Q_{0,1}(18)$ 7860	$\downarrow Q_{1,1}(19)$ 11006	$\downarrow Q_{2,1}(22)$ 9348	$\downarrow Q_{3,1}(21)$ 9584	$\downarrow Q_{4,1}(17)$ 9388	$\downarrow Q_{5,1}(16)$ 12056	$\downarrow Q_{6,1}(20)$ 12628	$\downarrow Q_{7,1}(23)$ 8408	$\downarrow Q_{8,1}(76)$ 8996	...
$\downarrow Q_{0,2}(26)$ 8372	$\downarrow Q_{1,2}(27)$ 10522	$\downarrow Q_{2,2}(31)$ 8612	$\downarrow Q_{3,2}(28)$ 8922	$\downarrow Q_{4,2}(25)$ 8602	$\downarrow Q_{5,2}(24)$ 12040	$\downarrow Q_{6,2}(30)$ 11200	$\downarrow Q_{7,2}(29)$ 8996	...	
$\downarrow Q_{0,3}(34)$ 9784	$\downarrow Q_{1,3}(38)$ 8394	$\downarrow Q_{2,3}(39)$ 11082	$\downarrow Q_{3,3}(35)$ 8734	$\downarrow Q_{4,3}(33)$ 9022	$\downarrow Q_{5,3}(32)$ 11942	$\downarrow Q_{6,3}(36)$ 11626	$\downarrow Q_{7,3}(37)$ 9416		
$\downarrow Q_{0,4}(42)$ 10188	$\downarrow Q_{1,4}(44)$ 8716	$\downarrow Q_{2,4}(47)$ 9928	$\downarrow Q_{3,4}(43)$ 9238	$\downarrow Q_{4,4}(41)$ 9284	$\downarrow Q_{5,4}(40)$ 11448	$\downarrow Q_{6,4}(45)$ 9262	$\downarrow Q_{7,4}(46)$ 8744		
$\downarrow Q_{0,5}(50)$ 10100	$\downarrow Q_{1,5}(52)$ 9546	$\downarrow Q_{2,5}(54)$ 9564	$\downarrow Q_{3,5}(51)$ 8958	$\downarrow Q_{4,5}(49)$ 9490	$\downarrow Q_{5,5}(48)$ 12164	$\downarrow Q_{6,5}(53)$ 11526	$\downarrow Q_{7,5}(55)$ 8448		
$\downarrow Q_{0,6}(58)$ 12850	$\downarrow Q_{1,6}(60)$ 10982	$\downarrow Q_{2,6}(63)$ 11702	x	$\downarrow Q_{4,6}(57)$ 8634	$\downarrow Q_{5,6}(56)$ 12668	$\downarrow Q_{6,6}(61)$ 12104	$\downarrow Q_{7,6}(62)$ 8358		
$\downarrow Q_{0,7}(67)$ 12054	x	$\downarrow Q_{2,7}(70)$ 11766		$\downarrow Q_{4,7}(65)$ 9088	$\downarrow Q_{5,7}(64)$ 12286	$\downarrow Q_{6,7}(71)$ 12058	$\downarrow Q_{7,7}(69)$ 8714		
$\downarrow Q_{0,8}(74)$ 8918		$\downarrow Q_{2,8}(78)$ 10306		$\downarrow Q_{4,8}(73)$ 8112	$\downarrow Q_{5,8}(72)$ 11632	x	$\downarrow Q_{7,8}(77)$ 8492		
...		

Пример для
 $n=45, m=201,$
8 CPU

«Однобоксовой» сигнал:

- полный перебор $O(m^n)$
- наш алгоритм $O(n^2m^3)$

«Двухбоксовой» сигнал:

- полный перебор $O(m^nd^n)$
- наш алгоритм $O(n^2m^3d^3)$

(n – число последовательностей,
 m – максимальная длина,
 d – интервал расстояний между
 боксами сигнала)

Волновая вычислительная схема на двумерной ε -сети перестановок
 мощностью порядка n^2 (в полном пространстве $n!$ перестановок):

- 1) отсутствует жёсткая привязка к числу процессоров кластера
- 2) линейный рост производительности от числа доступных процессоров в широком диапазоне (проверено на МВС-1000М МСЦ, до 512 CPU)

Wavelike computation scheme

Using 2D queue of permutations (P, Q) instead of straight one

$P_0(0) \rightarrow$	$P_1(1) \rightarrow$	$P_2(2) \rightarrow$	$P_3(3) \rightarrow$	$P_4(4) \rightarrow$	$P_5(5) \rightarrow$	$P_6(6) \rightarrow$	$P_7(7) \rightarrow$	$P_8(59) \rightarrow$	$P_9(68) \rightarrow$	$P_{10}(79) \rightarrow \dots$
175.8	206.0	201.6	260.6	211.7	198.8	197.6	207.7	218.7	184.2	214.2
$\downarrow Q_{0,0}(11)$	$\downarrow Q_{1,0}(12)$	$\downarrow Q_{2,0}(14)$	$\downarrow Q_{3,0}(13)$	$\downarrow Q_{4,0}(8)$	$\downarrow Q_{5,0}(10)$	$\downarrow Q_{6,0}(9)$	$\downarrow Q_{7,0}(15)$	$\downarrow Q_{8,0}(66)$	$\downarrow Q_{9,0}(75)$...
226.6	242.1	244.9	211.6	189.7	276.1	267.2	227.7	207.7	260.7	
$\downarrow Q_{0,1}(18)$	$\downarrow Q_{1,1}(19)$	$\downarrow Q_{2,1}(22)$	$\downarrow Q_{3,1}(21)$	$\downarrow Q_{4,1}(17)$	$\downarrow Q_{5,1}(16)$	$\downarrow Q_{6,1}(20)$	$\downarrow Q_{7,1}(23)$	$\downarrow Q_{8,1}(76)$...	
178.6	250.1	212.5	217.8	213.3	274.0	287.0	191.0	204.5		
$\downarrow Q_{0,2}(26)$	$\downarrow Q_{1,2}(27)$	$\downarrow Q_{2,2}(31)$	$\downarrow Q_{3,2}(28)$	$\downarrow Q_{4,2}(25)$	$\downarrow Q_{5,2}(24)$	$\downarrow Q_{6,2}(30)$	$\downarrow Q_{7,2}(29)$...		
190.3	239.1	195.7	202.8	195.5	273.6	254.5	204.5			
$\downarrow Q_{0,3}(34)$	$\downarrow Q_{1,3}(38)$	$\downarrow Q_{2,3}(39)$	$\downarrow Q_{3,3}(35)$	$\downarrow Q_{4,3}(33)$	$\downarrow Q_{5,3}(32)$	$\downarrow Q_{6,3}(36)$	$\downarrow Q_{7,3}(37)$			
222.4	190.8	251.9	198.5	205.0	271.4	264.2	214.0			
$\downarrow Q_{0,4}(42)$	$\downarrow Q_{1,4}(44)$	$\downarrow Q_{2,4}(47)$	$\downarrow Q_{3,4}(43)$	$\downarrow Q_{4,4}(41)$	$\downarrow Q_{5,4}(40)$	$\downarrow Q_{6,4}(45)$	$\downarrow Q_{7,4}(46)$			
231.5	198.1	225.6	210.0	211.0	260.2	210.5	198.8			
$\downarrow Q_{0,5}(50)$	$\downarrow Q_{1,5}(52)$	$\downarrow Q_{2,5}(54)$	$\downarrow Q_{3,5}(51)$	$\downarrow Q_{4,5}(49)$	$\downarrow Q_{5,5}(48)$	$\downarrow Q_{6,5}(53)$	$\downarrow Q_{7,5}(55)$			
229.5	217.0	217.4	203.6	215.7	276.5	262.0	192.0			
$\downarrow Q_{0,6}(58)$	$\downarrow Q_{1,6}(60)$	$\downarrow Q_{2,6}(63)$	=====	$\downarrow Q_{4,6}(57)$	$\downarrow Q_{5,6}(56)$	$\downarrow Q_{6,6}(61)$	$\downarrow Q_{7,6}(62)$			
292.0	249.6	266.0		196.2	287.9	275.1	190.0			
$\downarrow Q_{0,7}(67)$	=====	$\downarrow Q_{2,7}(70)$		$\downarrow Q_{4,7}(65)$	$\downarrow Q_{5,7}(64)$	$\downarrow Q_{6,7}(71)$	$\downarrow Q_{7,7}(69)$			
274.0		267.6		206.5	279.2	274.0	198.0			
$\downarrow Q_{0,8}(74)$		$\downarrow Q_{2,8}(78)$		$\downarrow Q_{4,8}(73)$	$\downarrow Q_{5,8}(72)$	=====	$\downarrow Q_{7,8}(77)$			
202.7		234.2		184.4	264.4		193.0			
...			

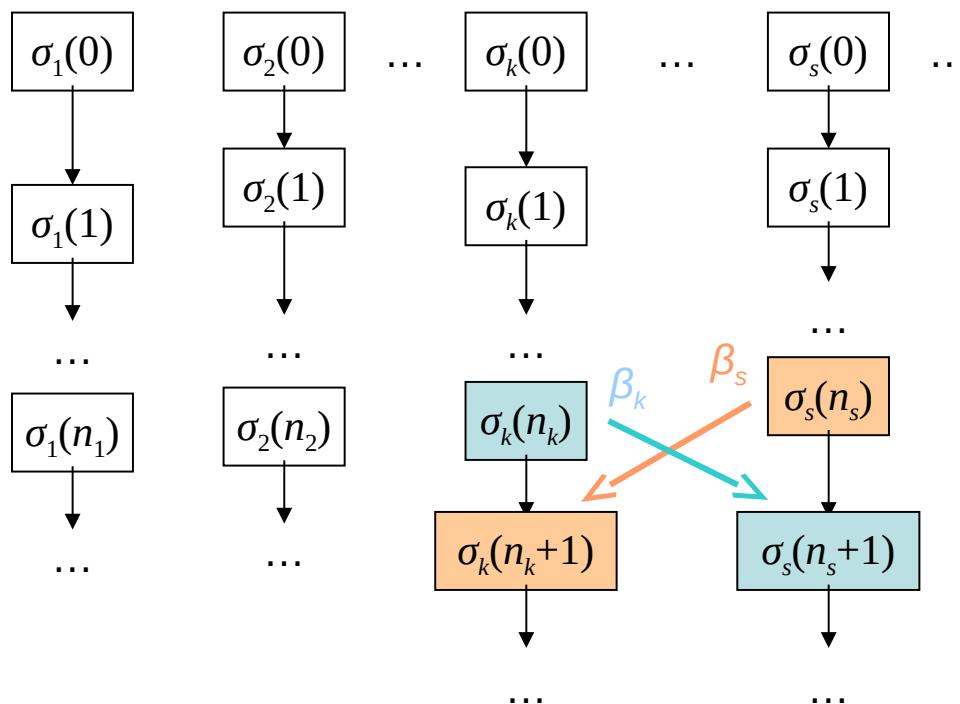
$n=45$,

$m=201$,

$l=15$,

8 CPU's

Параллельная реализация вычислительно трудоемких алгоритмов: реконструкция эволюции регуляторного сигнала в группе геномов



Индивидуальные режимы охлаждения

$$\beta_i(n) = \frac{C}{1 + B(i - 1)} \log^p (n + 1)$$

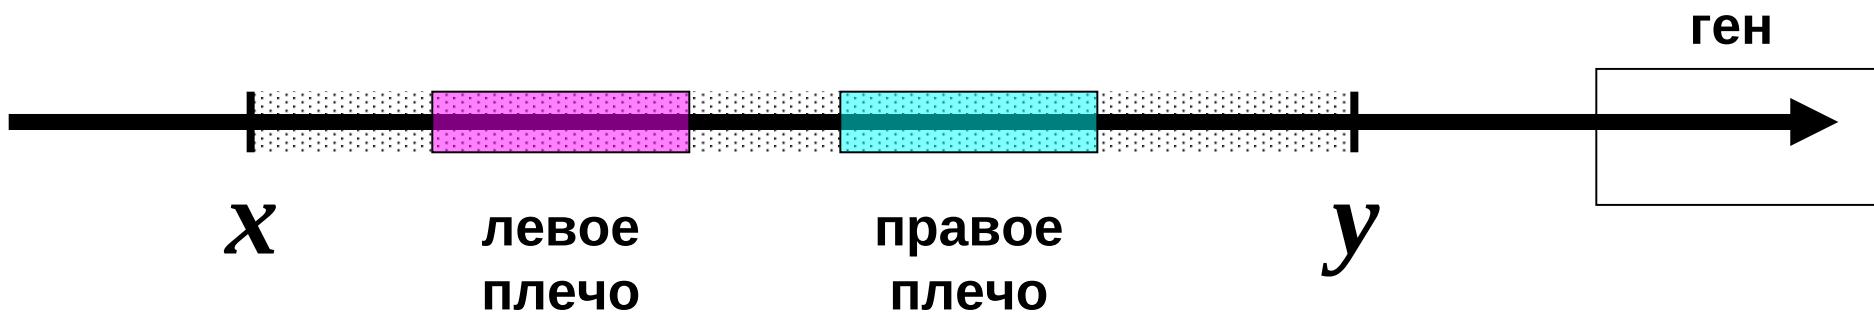
Периодический обмен параметрами охлаждения между находящимися в окрестности различных локальных или условных минимумов цепями с разной температурой способствует выходу из оврагов и локальных минимумов поверхности отклика.

Усовершенствованная **параллельная схема аннилинга** МС³

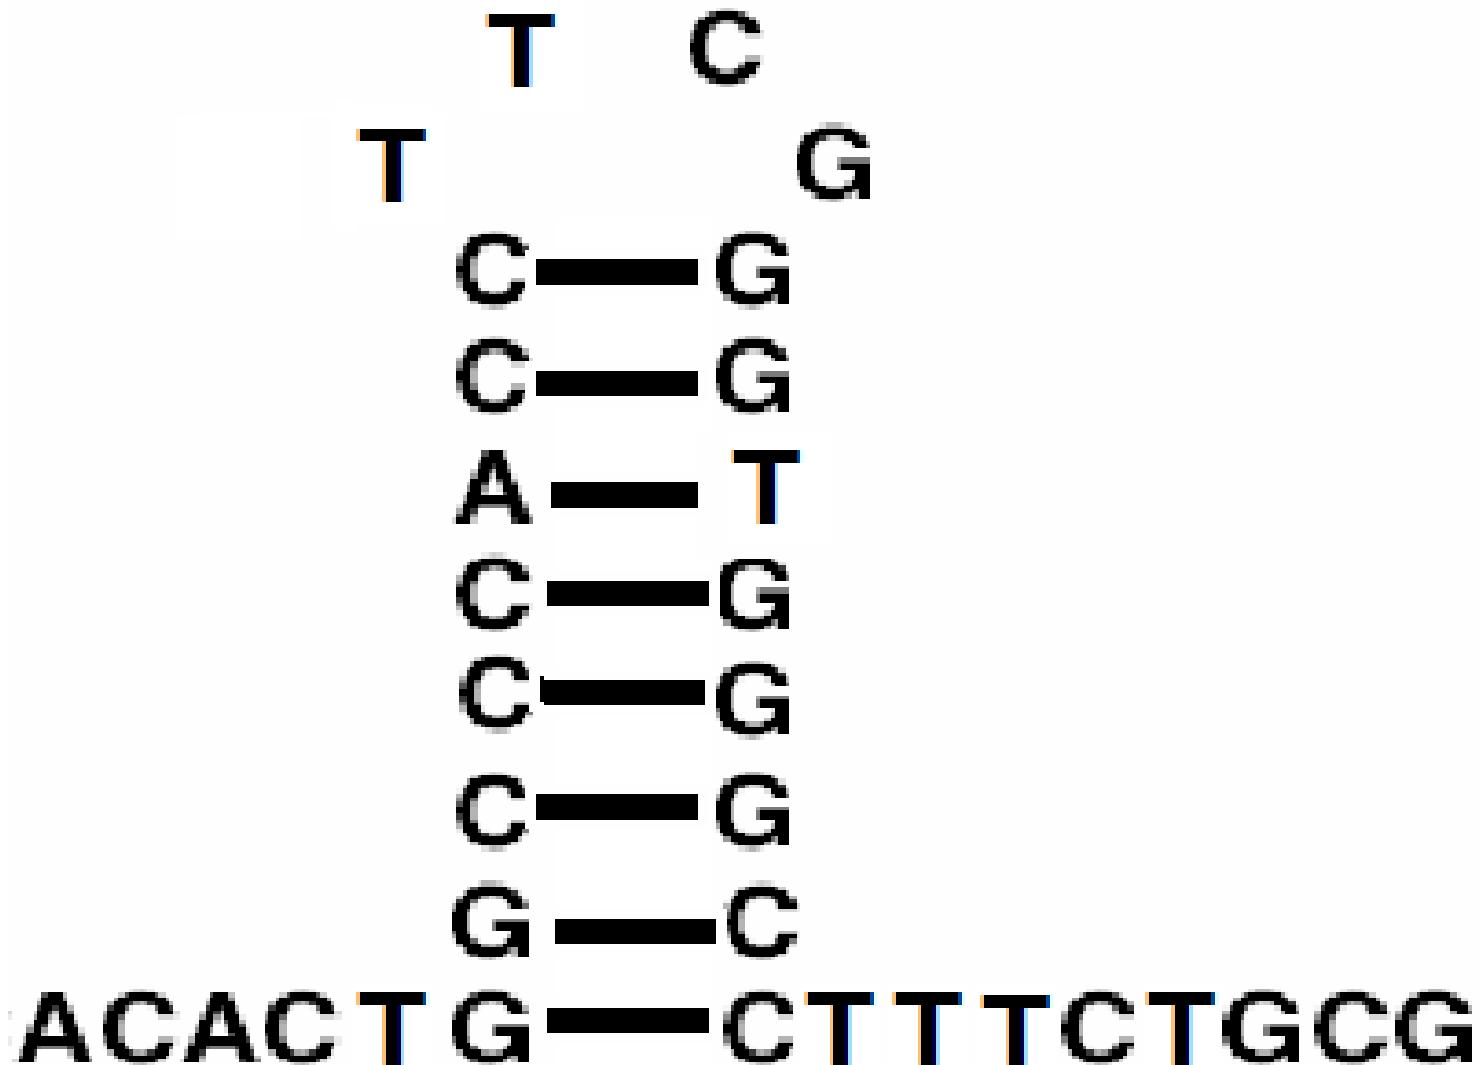
(= Metropolis-Coupled Markov Chain Monte-Carlo):

- 1) лучшее покрытие множества минимальных конфигураций
- 2) меньшая зависимость от выбранной начальной точки
- 3) более быстрая сходимость к одному из предполагаемых абсолютных минимумов функционала «энергии»

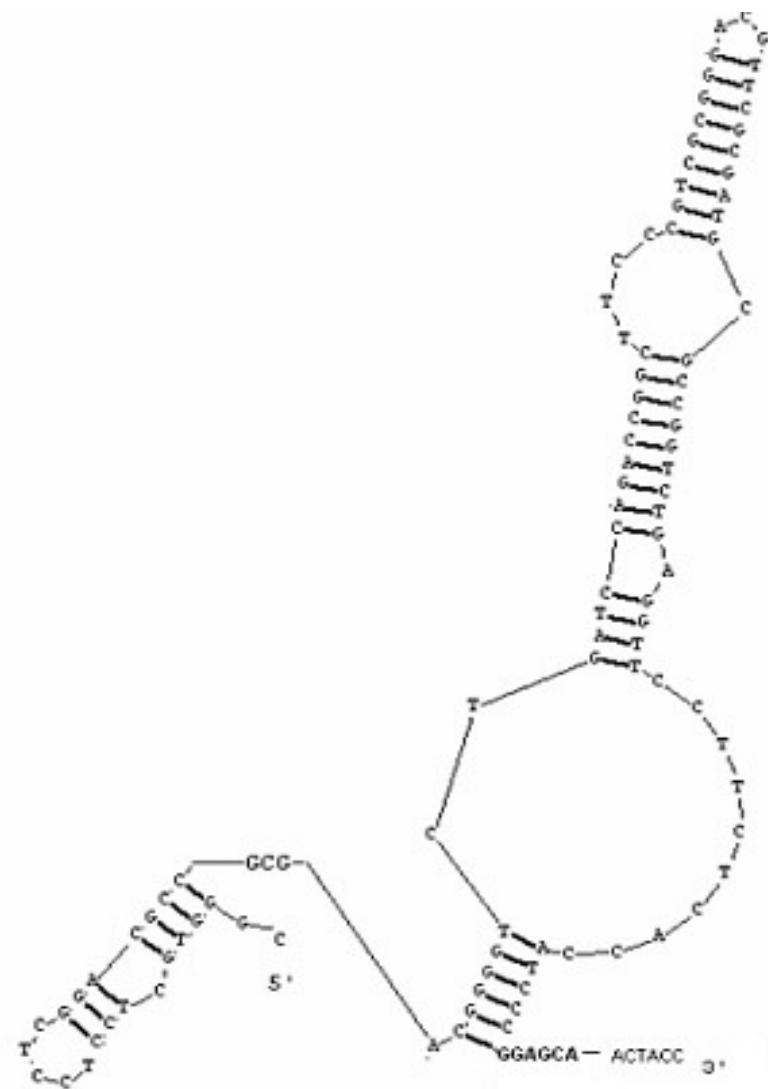
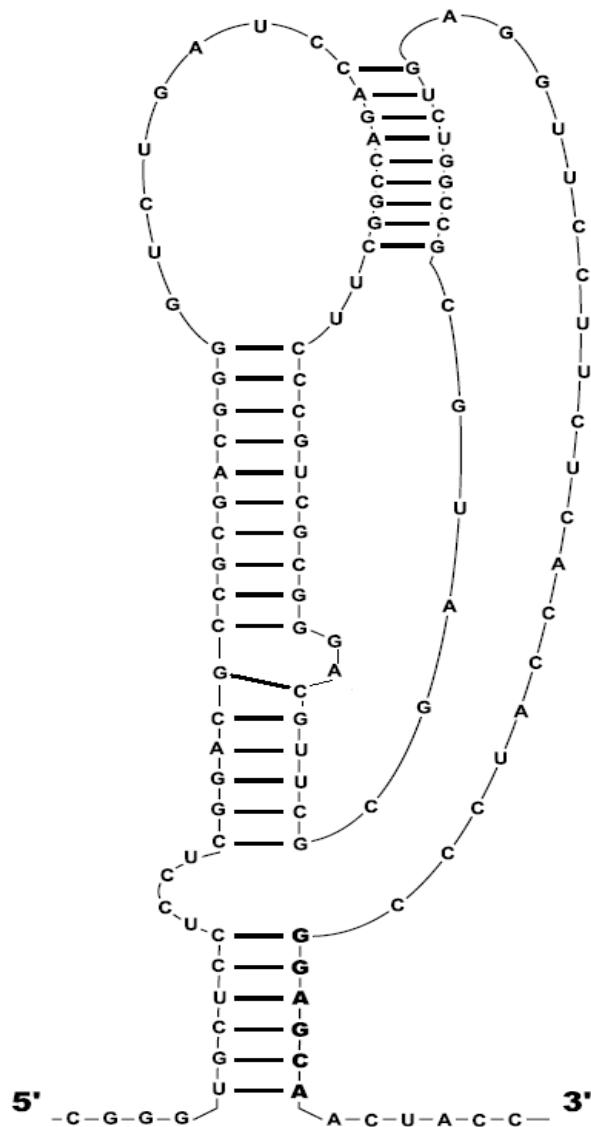
Показана лидерная область перед геном,
в ней «**окно**» с концами x и y ,
а в окне образуются «**спирали**»

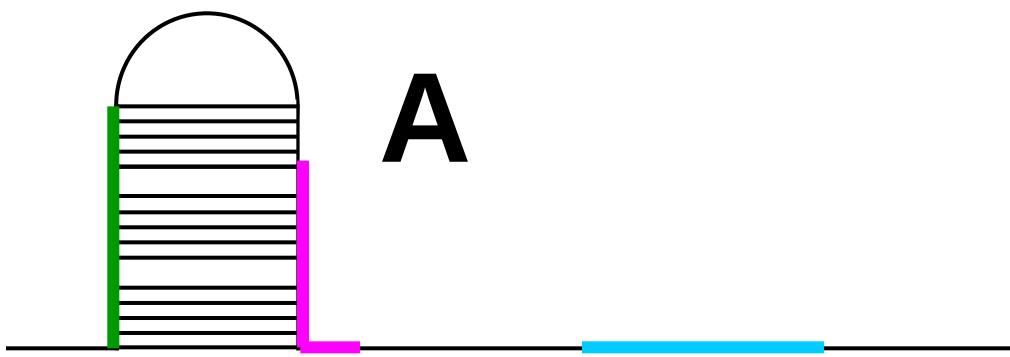
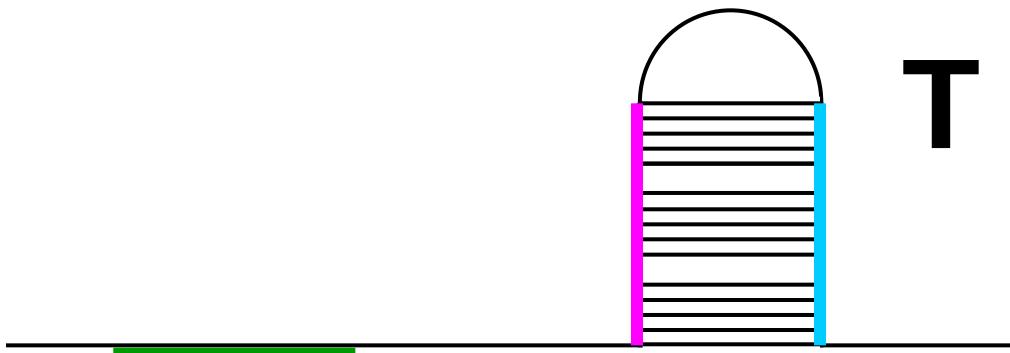


**«Спираль» с «плечами»,
склеиваются G с C и A с T:**

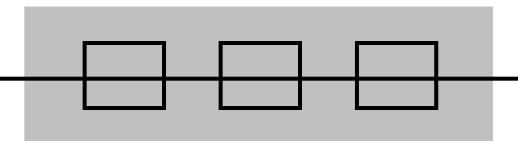


Реальные еще очень простые вторичные структуры (=наборы спиралей):





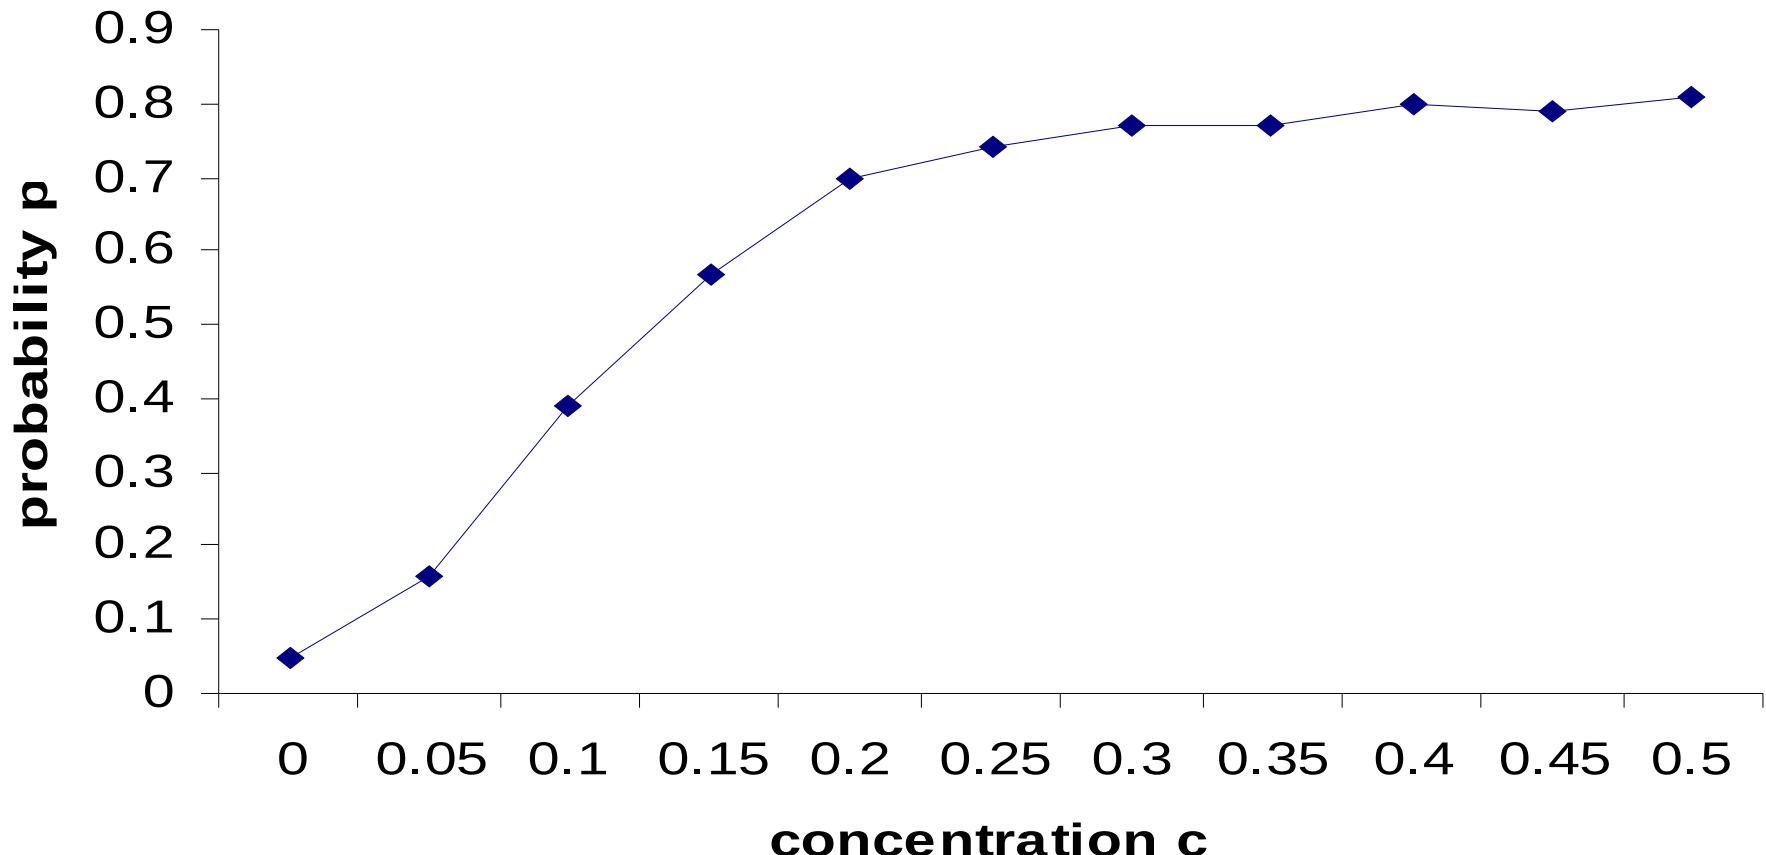
лидерная область



Два состояния сигнала. Результат определяется тем, какая из двух альтернативных вторичных структур образуется: «Т» или «А»

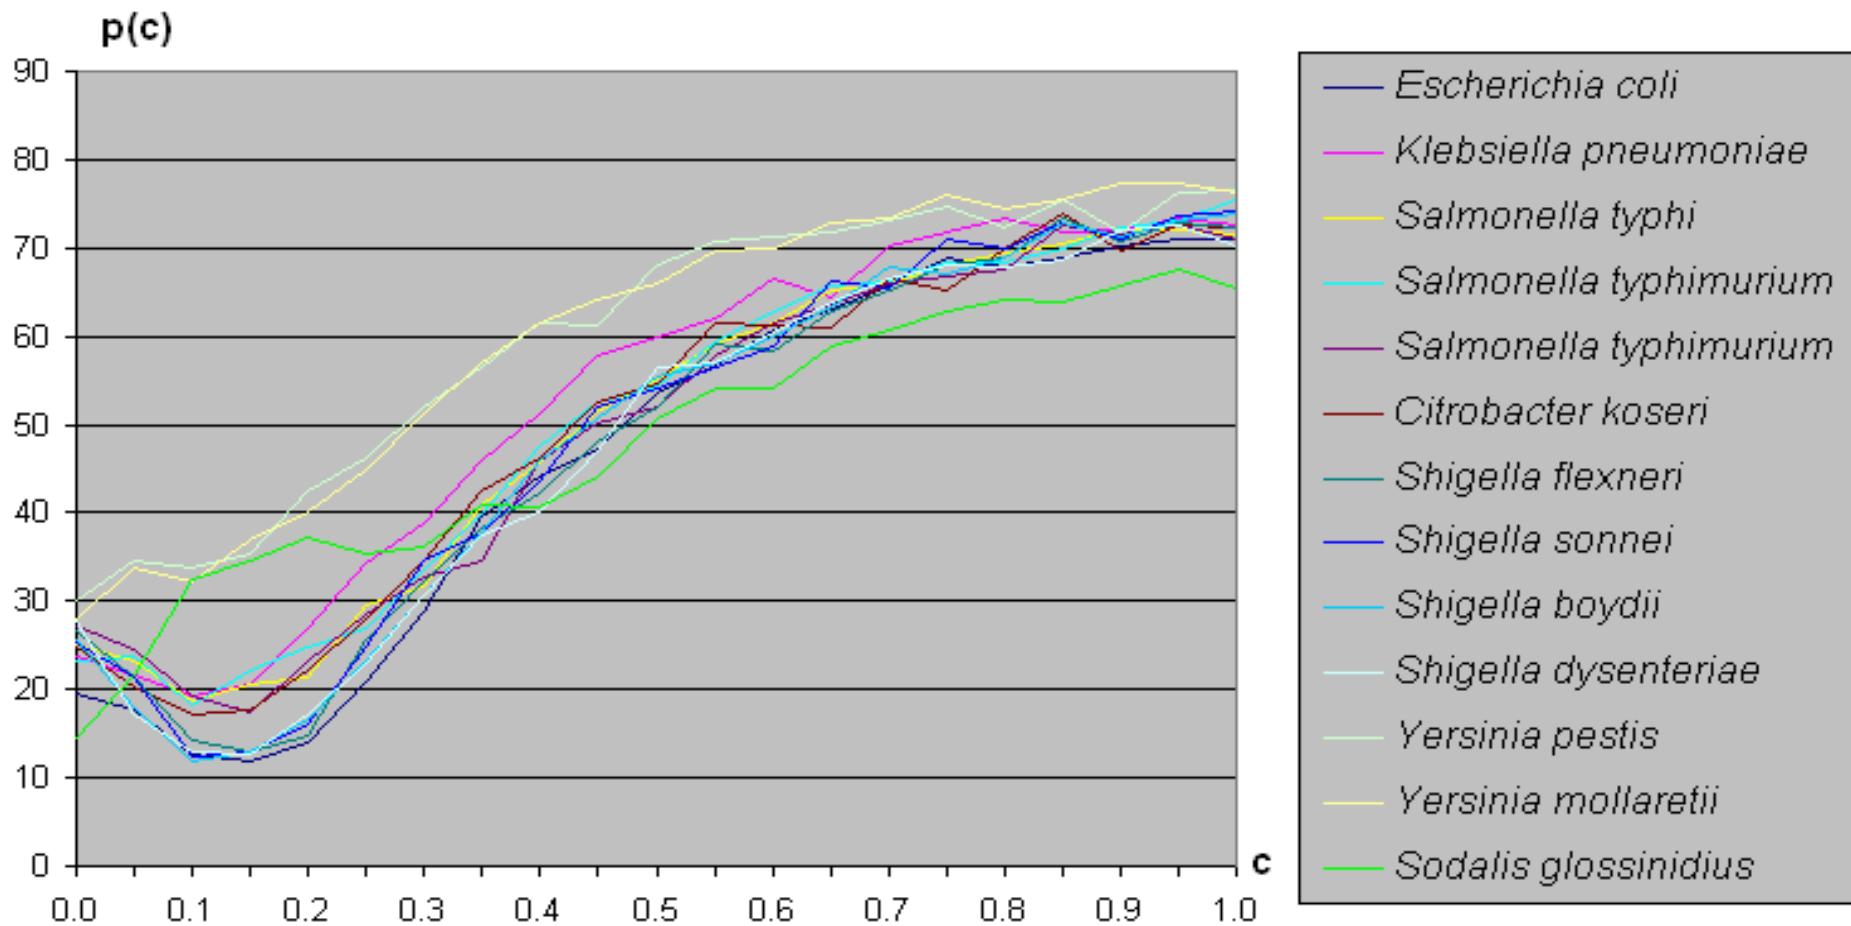
Результат одной нашей модель регуляции:

Vibrio cholerae trp



Примеры результатов счета в этой модели

Мы считали функцию $p=p(c)$ для практических лидерных областей аминокислотных оперонов и аминоацил-тРНК синтетаз. Имеется **высокое согласие с экспериментом**, с одной стороны, и **предсказание многих новых случаев такой регуляции**, с другой стороны. Здесь показаны *thrA* опероны у гамма-протеобактерий.

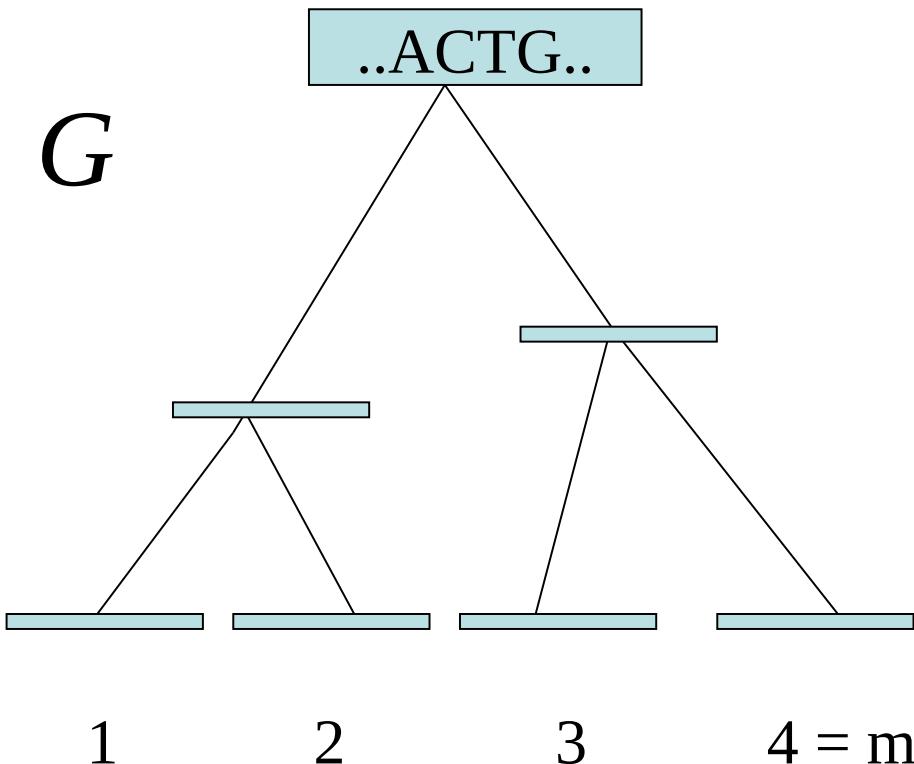


Два основных направления
нашей работы в Биоинформатике:

- 1) Модели и алгоритмы регуляции генов,**
- 2) Модели и алгоритмы эволюции этих
регуляций (=сигналов)**

Дано дерево G , у которого длины ребер соответствуют времени переходу от предка к потомку.

Даны современные последовательности

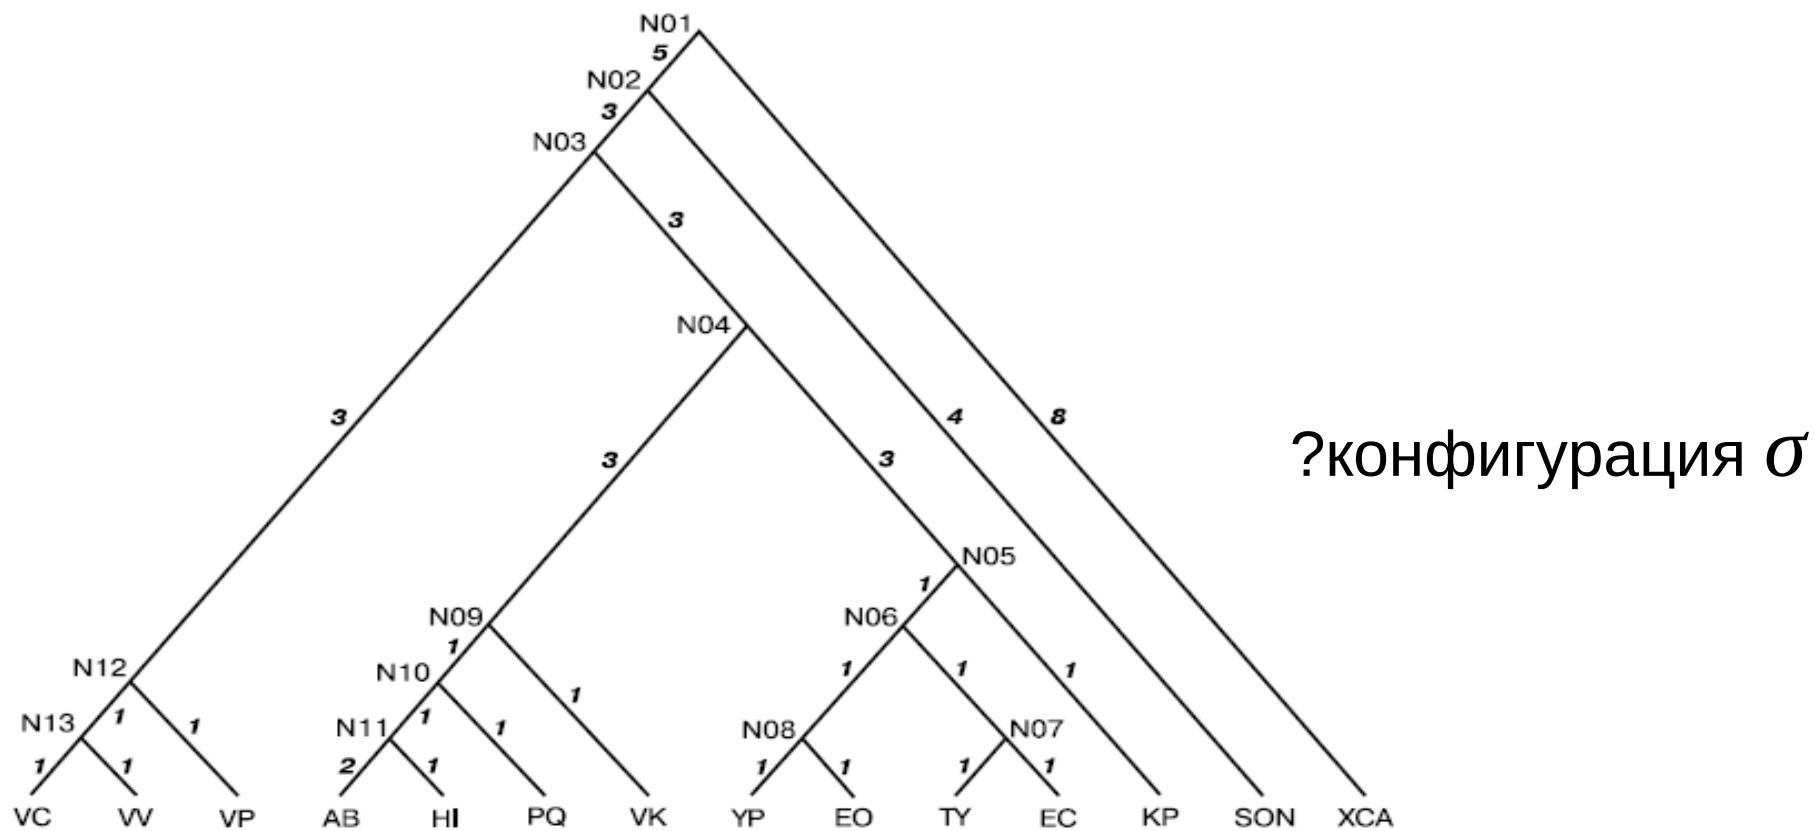


Ищем все предковые последовательности

Иногда **ищется** и само дерево G : тогда
даны только современные последователь-
ности.

Эти заданные последовательности –
организмы, виды, гены, белки, сигналы

Классическая аттенюаторная регуляция биосинтеза треонина у гамма-протеобактерий



VC = *Vibrio cholerae*, VV = *Vibrio vulnificus*, VP = *Vibrio parahaemolyticus*,
AB = *Actinobacillus actinomycetemcomitans*, HI = *Haemophylus influenzae*,
PQ = *Mannheimia haemolytica*, VK = *Pasterella multocida*, YP = *Yersinia pestis*,
EO = *Erwinia carotovora*, TY = *Salmonella typhi*, XCA = *Xanthomonas campestris*,
EC = *Escherichia coli*, KP = *Klebsiella pneumoniae*, SON = *Shewanella oneidensis*

Наша модель эволюции сигнала:

$$H(\sigma) = H_1(\sigma) + H_2(\sigma) \rightarrow \text{gl min}$$

Такая функция минимизируется с помощью **алгоритма аннилинга**. На каждом его шаге текущая конфигурация σ заменяется на новую $\tilde{\sigma}$ из определенного списка возможностей с вероятностью

$$q(\sigma, \tilde{\sigma}) = \exp\left\{-\beta_m \cdot [H(\sigma) - H(\tilde{\sigma})]^+\right\}$$

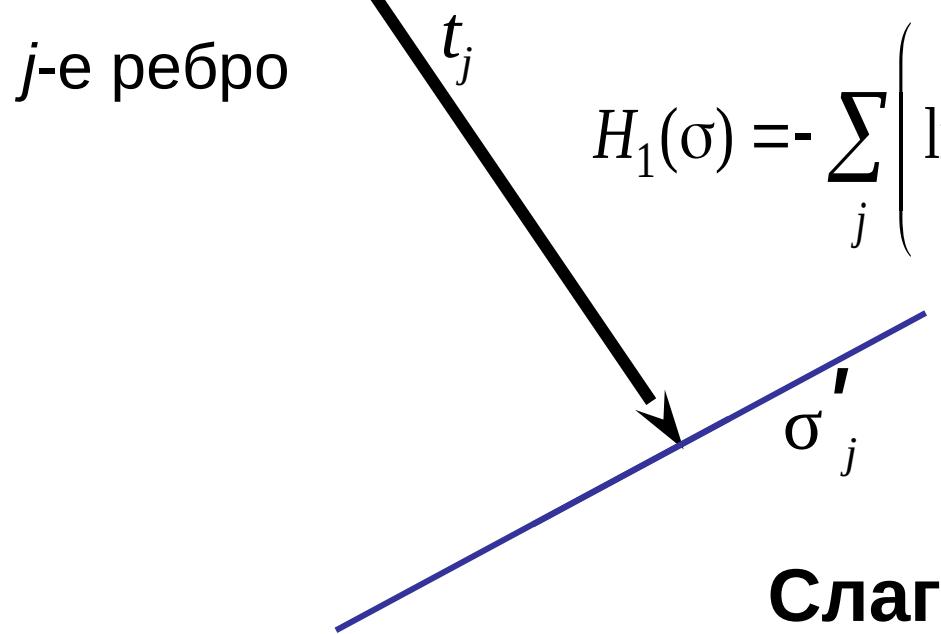
или остается прежней с вероятностью $(1 - q)$.

Нами **доказана** сходимость к **глобальному min** при условии

$$\lim_{m \rightarrow \infty} \frac{\log m}{\beta_m} > const$$

Показано одно ребро от некоторой конфигурации σ . На этом ребре за время t_j происходят: **замены букв со скоростями R , вставки букв и делеции букв.**

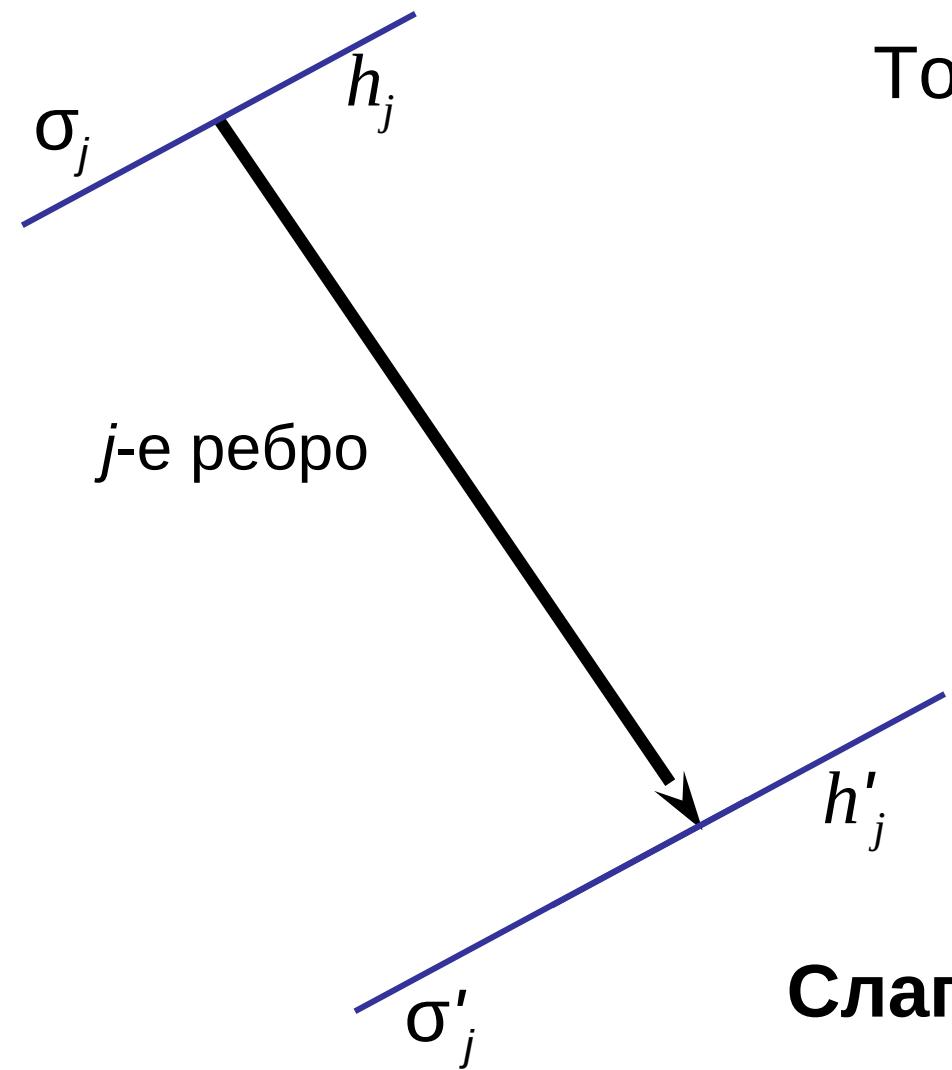
Сначала **выравниваем** позиции у σ_j и σ'_j , при этом возникают **пустые позиции**. Длины участков с пустыми позициями обозначим l_{jm} . Тогда:



$$H_1(\sigma) = - \sum_j \left(\ln \prod_{i \in j}^n \left(e^{\gamma_i t_j R} \right) (\bar{\sigma}_{ji}, \bar{\sigma}'_{ji}) - 10 \cdot \sum_m (l_{jm} + 1) \right)$$

Слагаемое $H_1(\sigma)$ в функции H

Показано одно ребро от конфигурации σ . На этом ребре произошел переход от вторичной структуры h_j в σ_j к вторичной структуре h'_j в σ'_j .



Тогда:

$$H_2(\sigma) = - \sum_j \Phi(h_j, h'_j)$$

Слагаемое $H_2(\sigma)$ в функции H

Решение (фрагмент): эволюция предкового сигнала

gGTTGGGGCGGGCcgtgtttcgaaaaatttaatgacGAGCCCGCATCCAATaaaGATGC_{GGG}CattTCcctc
gGTTGGGGCGGGCTgtgtactcaaaaaatttAAAGAcGAGCCCGCATCCAACaaaGATGC_{GGG}CTtTTTTt
TGTTGGGGCGGGCTgtgcgcacaagaaattccAAAAAAAAGCCCGATCCAACAAaGATGC_{GGG}CTTTTTTa
TGTTGGGGCAGGCTgtgagcgaaagaaattcaAAAAAAAAGGCCGTATCCAACAAaGATACAGGC_{CTTTTT}ta
TGTTGGGGCAGGCTgtgagcgaaagaaattcaAAAAAAAAGGCCGTATCCAATAAaGATACAGGC_{CTTTTT}ta
TGTTGGGGCAGGCTgtgagcgaaaattcacAAAAAAAAGGCCGTATCCAACcGATACAGGC_{CTTTTT}ta

N01: H3=-29.2
N02: H3=-51.3
N03: H3=-45.1
N12: H3=-61.3
N13: H3=-47.5
VC: Σ=-234.3

gGTTGGGGCGGGCcgtgtttcgaaaaatttaatgacGAGCCCGCATCCAATaaaGATGC_{GGG}CattTCcctc
gGTTGGGGCGGGCTgtgtactcaaaaaatttAAAGAcGAGCCCGCATCCAACaaaGATGC_{GGG}CTtTTTTt
TGTTGGGGCGGGCTgtgcgcacaagaaattccAAAAAAAAGCCCGATCCAACAAaGATGC_{GGG}CTTTTTTa
TGTTGGGGCAGGCTgtgagcgaaagaaattcaAAAAAAAAGGCCGTATCCAACAAaGATACAGGC_{CTTTTT}ta
TGTTGGGGCAGGCTgtgagcgaaagaaattcaAAAAAAAAGGCCGTATCCAATAAaGATACAGGC_{CTTTTT}ta
TGTTGGGGCAGGCTgtgagcgaaaagaaatttcAAAAAAAAGGCCGTATCCAACAAaGATACAGGC_{CTTTTT}ta

N01: H3=-29.2
N02: H3=-51.3
N03: H3=-45.1
N12: H3=-61.3
N13: H3=-61.3
VV: Σ=-248.1

gGTTGGGGCGGGCcgtgtttcgaaaaatttaatgacGAGCCCGCATCCAATaaaGATGC_{GGG}CattTCcctc
gGTTGGGGCGGGCTgtgtactcaaaaaatttAAAGAcGAGCCCGCATCCAACaaaGATGC_{GGG}CTtTTTTt
TGTTGGGGCGGGCTgtgcgcacaagaaattccAAAAAAAAGCCCGATCCAACAAaGATGC_{GGG}CTTTTTTa
TGTTGGGGCAGGCTgtgagcgaaagaaattcaAAAAAAAAGGCCGTATCCAACAAaGATACAGGC_{CTTTTT}ta
TGTTGGGGCAGGCTgtgagcgaaaagaaattcacAAAAAAAAGGCCGTATCCAACAAaGATACAGGC_{CTTTTT}ta

N01: H3=-29.2
N02: H3=-51.3
N03: H3=-45.1
N12: H3=-57.1
VP: Σ=-182.6

gGTTGGGGCGGGCcgtgtttcgaaaaatttaatgacGAGCCCGCATCCAATaaaGATGC_{GGG}CattTCcctc
gGTTGGGGCGGGCTgtgtactcaaaaaatttAAAGAcGAGCCCGCATCCAACaaaGATGC_{GGG}CTtTTTTt
TGTTGGGGCGGGCTgtgcgcacaagaaattccAAAAAAAAGCCCGATCCAACAAaGATGC_{GGG}CTTTTTTa
TGatGGTGC_{GGG}CTgtgcgcacaagaaaaatcAGAAAAAAAGCCCGACCCAaaaaaTG_{GGG}CTTTTTTa
aGAtgGTGC_{GGG}TTagtgtctgacaaaaaaatgaacAAAAAAACCGCACTCaacaaaaAG_{GGG}TTTTTtata
aaTGGTGC_{GGG}TTagtactggaaaaatgaacAAAAAAACCGCAaCTCAactaaaAG_{GGG}TTTTTtata
aaTGGTGC_{GGG}TTagtacggaaaaaaagaaacAAAAAAACCGCAaCTCAactgaaAG_{GGG}TTTTTtata
aaTGGGCGGGCttagtgcgttgaagaatagaattcatGAACCCGCaTTTCCC_{GAGa}GC_{GGG}TTTtttatg

N01: H3=-29.2
N02: H3=-51.3
N03: H3=-39.1
N04: H3=-24.6
N09: H3=-39.0
N10: H3=-51.0
N11: H3=-6.2
AB: Σ=-240.5

gGTTGGGGCGGGCcgtgtttcgaaaaatttaatgacGAGCCCGCATCCAATaaaGATGC_{GGG}CattTCcctc
gGTTGGGGCGGGCTgtgtactcaaaaaatttAAAGAcGAGCCCGCATCCAACaaaGATGC_{GGG}CTtTTTTt
TGTTGGGGCGGGCTgtgcgcacaagaaattccAAAAAAAAGCCCGATCCAACAAaGATGC_{GGG}CTTTTTTa
TGatGGTGC_{GGG}CTgtgcgcacaagaaaaatcAGAAAAAAAGCCCGACCCAaaaaaTG_{GGG}CTTTTTTa
aGAtgGTGC_{GGG}TTagtgtctgacaaaaaaatgaacAAAAAAACCGCACTCaacaaaaAG_{GGG}TTTTTtata
aaTGGTGC_{GGG}TTagtactggaaaaatgaacAAAAAAACCGCAaCTCAactaaaAG_{GGG}TTTTTtata
aaTGGTGC_{GGG}TTagtacggaaaaaaagaaacAAAAAAACCGCAaCTCAactgaaAG_{GGG}TTTTTtata
aaTGGTGC_{GGG}TTagtgcagaaaaacaagatacAGAAAAACCGCGATTCAactGAATaGC_{GGG}TTTTTtata

N01: H3=-29.2
N02: H3=-51.3
N03: H3=-39.1
N04: H3=-24.6
N09: H3=-39.0
N10: H3=-51.0
N11: H3=-35.0
HI: Σ=-269.3

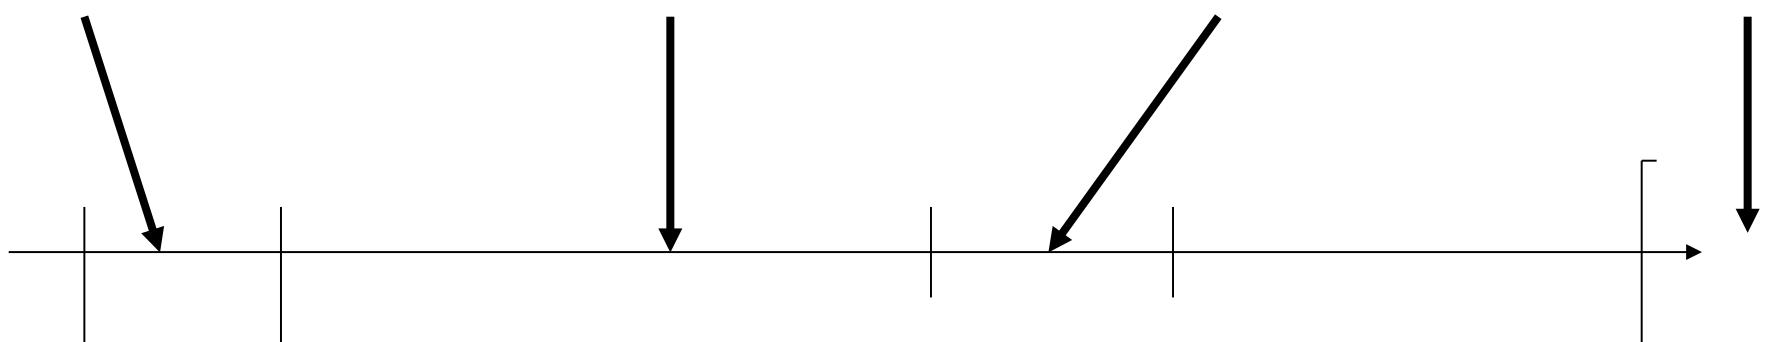
Поиск и эволюция сигнала другого типа «промотора»: некоторой комбинации слов с условиями на них и расстояния

TTGaca

...17-18н...

TAtaaT

стр. ген

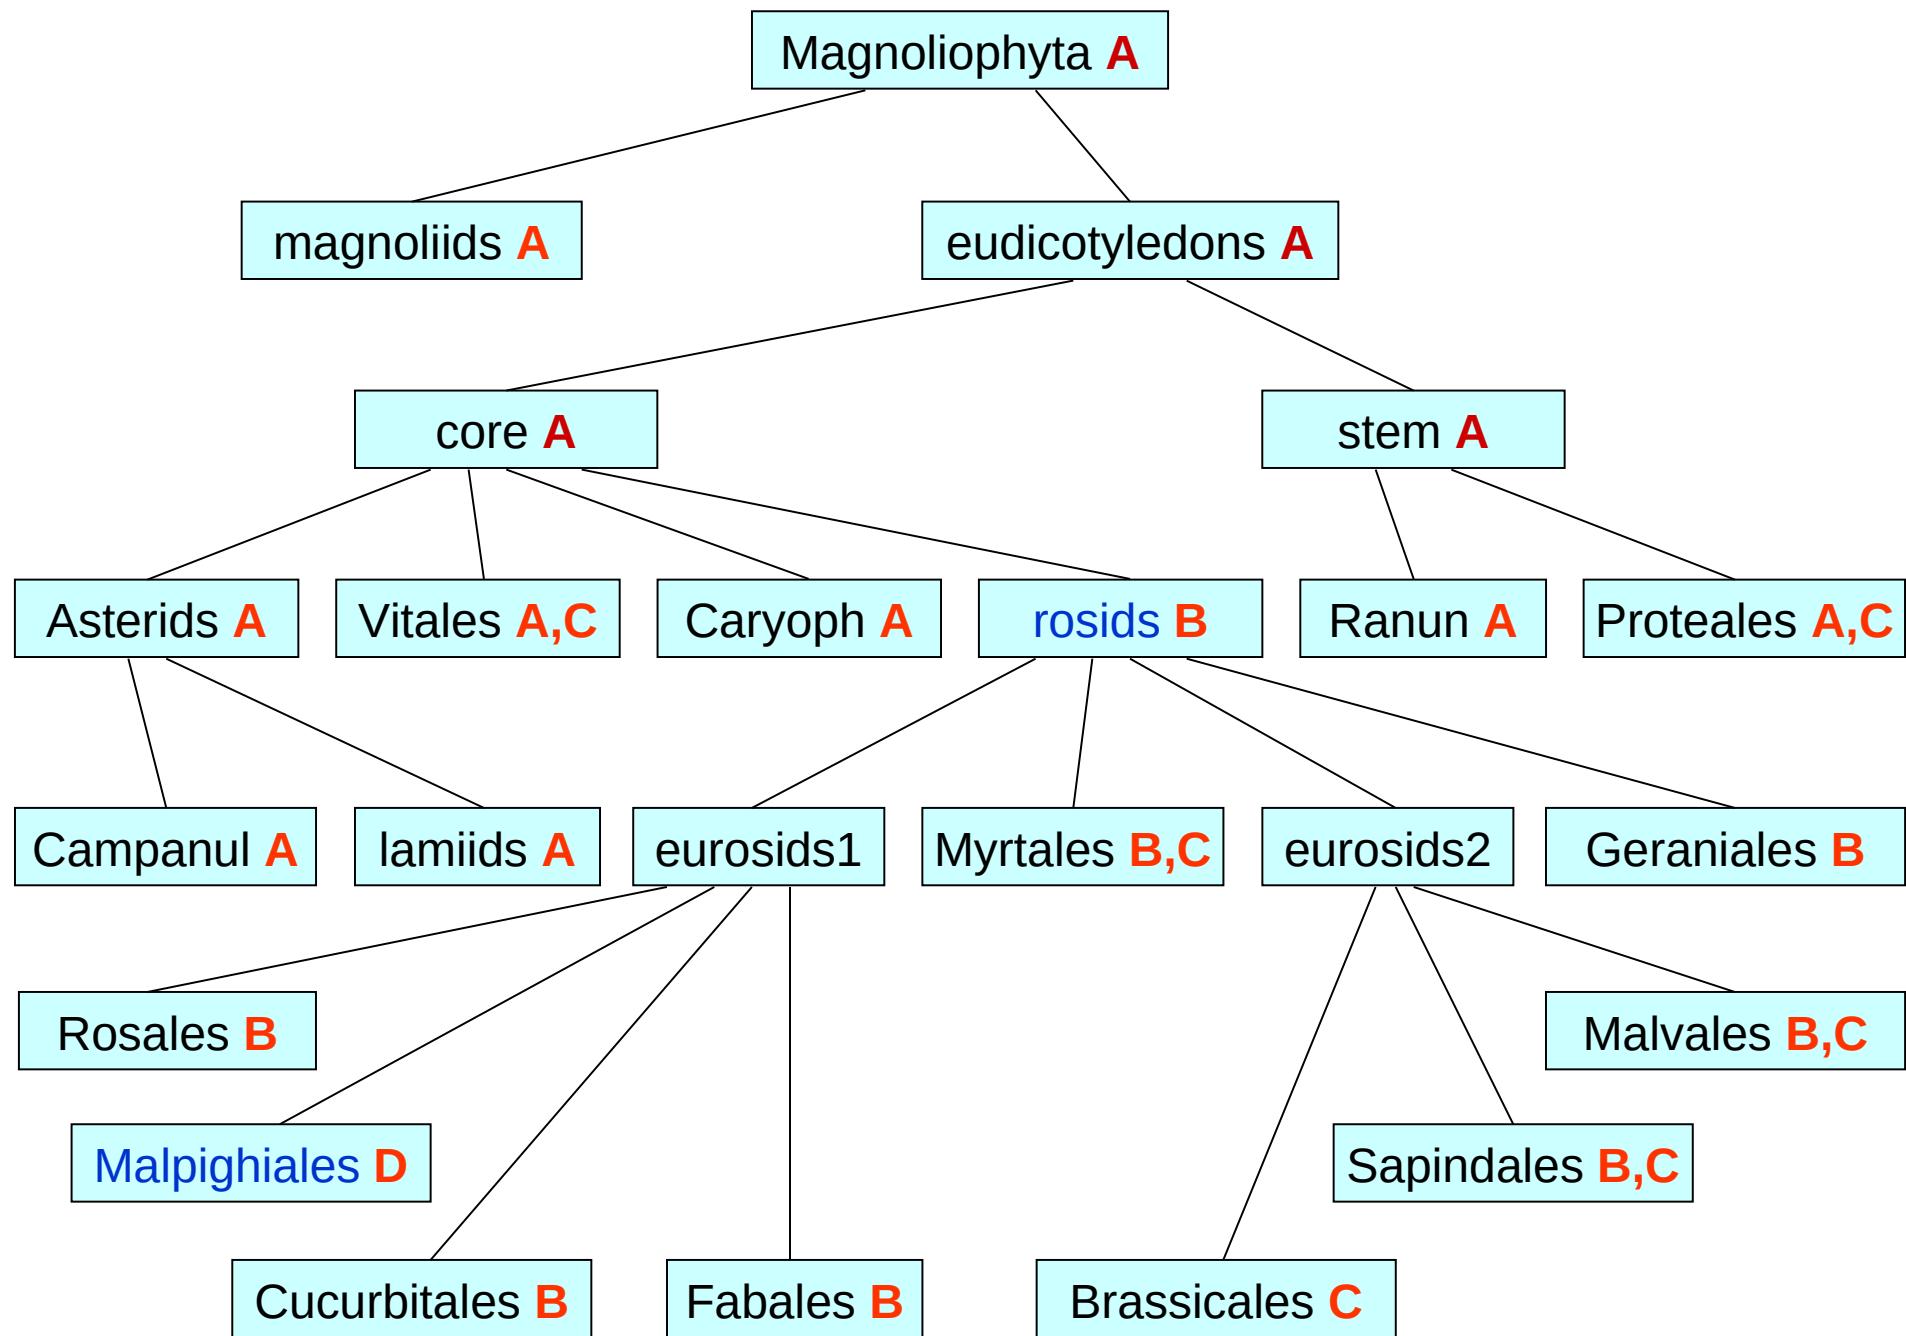


На следующем слайде показан удивительно консервативный (=устойчивый при эволюции) промотор (перед геном *psbA* в пластидах)

На слайде через один показан противоположный случай: быстро эволюционирующий (меняющийся) промотор среди цветковых растений (перед геном *ndhF* в пластидах). Он имеет четыре варианта A, B, C, D, сменяющие друг друга. Сами эти промоторы найдены, но здесь не приведены.

TTGACA TGGCT=ATATAAGTCATGT**TATACT**
TTGACA CGGG=CATATAAGGCAT**TGT****TATACT**
TTCACGATA==TATATAAGTCATACT**TATACT**
TTGACA TACA=GATATGTCTCATATT**TATACT**
TTGACA TTGAT=ACATGGATCATATT**TATACT**
TTGACT TTAAT=AAACCATTCT**TGT****TATACT**
TTGACA CGGAT=AGGTTTT=GT**GATATGCT**
TTGACA TCAAT=AGATAAGTTGTGT**TATACT**
TTGACA TATAT=GGAAAGATCAT**TGT****TATACT**
TTGACA CAAA=AAGAAAGATTGTGT**AATATT**
TTGACA TAC=TAATGGGATATGTGT**AATAAT**
TTGACA TAA=TCATATGTTATGTGT**AATACT**
TTGACA TAA=TAATACATTCT**TGT****AATACT**
TTGACA TTT=TTATACTTACATACT**TATAAT**
TTGACA TTAGTTACGT=TTGT**GCAATACT**
TTGACA GCT=TAAGGTTAAT=ATGT**AATAAT**
TTGACA ACAG=CATTAACATCT**GTAATAAT**
TTGACA AATA=AACATCATT=TGG**CATAAT**
TTGATT AATATAA=ATTAAATT=GT**TATAAT**

Arabidop
Spinacia
Cycas
Cryptomer
Pinus
Welwitsch
Adiantum
Angiopter
Psilotum
Huperzia
Aneura
Marchantia
Physcomitr
Chara
Chaetospha
Staurastr
Zygnema
Mesostig
Bigelowiel



Пример интересной темы для исследования – **связь (REP) промоторов и предпочитаемых ими сигма-субъединиц.**

Например, нами показано, что промотор **C** предпочтительно связывает Sig4-субъединицу РНК-полимеразы. Аналогично для фаговых промоторов и полимераз.

Переходы, возможные в нашей модели регуляции, которая связана со спиралями:

- (1) Правый конец **у** окна **сдвигается** на один нуклеотид вправо **или остается** на месте **или подается** сигнал «Т». Альтернатива: когда правый конец **у** доходит до начала гена, то **подается** сигнал «А». При этом вторичная структура в окне формирует выбор между Т или А;
- (2) Левый конец **х** окна **сдвигается** на три нуклеотида вправо **или остается** на месте, что зависит от частоты с предшествующего считывания регулируемого гена;
- (3) Вторичная структура **преобразуется** в окне, т.е. текущая вторичная структура ω трансформируется в новую структуру ω' .

В модели с предыдущего слайда ищется (выход алгоритма) зависимость $p(c)$ – частота наступления состояния «Т» (несчитывания гена), при каждом фиксированном значении частоты считывания («концентрации») c .

При наличии такой регуляции график $p(c)$ имеет вид, показанный на слайдах 24 и 25. При ее отсутствии график $p(c)$ имеет вид почти постоянной функции или даже убывающей функции.

Что можно читать по этим темам:

1а) тип сигнала – «вторичная структура»:

[[Lyubetsky, Pirogov, Rubanov, Seliverstov, 2007, Journal of Bioinformatics and Computational Biology, vol 5, no 1, p. 155-180](#)],

1б) тип сигнала – «промотор»:

[[Селиверстов, Лысенко, Любецкий, 2009, Физиология растений РАН, том 56, № 5; Seliverstov, Lyubetsky Молекулярная биология, представлена](#)]

2) Модели эволюции этих регуляций, т.е. эволюции сигналов 1а и 1б:

[[Любецкий, Жижина, Рубанов, 2008, Гиббсовский подход в задаче эволюции регуляторного сигнала экспрессии гена, ППИ, №4; Горбунов, Любецкий МолБио, представлена](#)]

Статьи можно получить от авторов по адресу: gorbunov@iitp.ru

Наши биологические результаты (дает некоторый обзор, для слушателей не обязателен)

1. Проведена реконструкция эволюционных событий молекулярного уровня:

построены деревья белков и согласующие их деревья видов, найдены **события потенциальных горизонтальных переносов, потерь и дупликаций генов**, случаи массовой дупликации генов в предковом геноме, статистические характеристики эволюционных событий по вершинам дерева видов и по таксономическим группам, **сравнивались сценарии горизонтальных переносов против дупликаций и потерь генов.** [In the book: Bioinformatics of Genome Regulation and Structure II. Springer Science & Business Media, Inc. 2005]

2. Предложены новые типы регуляции экспрессии генов:

2.1 Регуляция на уровне *трансляции*, опосредованная Т-боксом, например, гена *iIeS*, кодирующего изолейцил-тРНК синтетазу, у Актинобактерий. [ВМС Microbiology, 2005, 5:54; Молекулярная биология, 2005, 39(6)]

2.2 Регуляция на уровне *трансляции* посредством взаимодействия рибосомы, транслирующей лидерный пептид, и вторичной структуры РНК для гена *IeuA*, кодирующего 2-изопропилмалатсинтазу, у Актинобактерий («**LEU-элемент**»). [ВМС Microbiology, 2005, 5:54; Молекулярная биология, 2005, 39(6)]

2.3 Сложные типы классической аттенюаторной регуляции (когда антирмина́тор не альтернати́вен термина́тору), например, у лактобацилл перед геном *ilvD*: это – цепь спиралей или псевдоузел. [готовится к печати]

2.4 Аттенюаторная регуляция генов *cysK* синтеза цистеина у Актинобактерий, вовлекающая ро-белок для терминации транскрипции: рибосома, транслирующая лидерный пептид, перекрывает сайт связывания ро-белка. [ВМС Microbiology, 2005, 5:54]

2.5 Регуляция гена *leuA* у альфа-протеобактерий, вовлекающая ген лидерного пептида и консервативный псевдоузел («LEU1-регуляция»). [готовится к печати]

2.6 Регуляция, опосредованная аномально длинной спиралью РНК, генов, кодирующих транспортёры двухвалентных катионов (*mntH*) и ферменты, зависимые от металлов (никель-зависимая глиоксалаза и др.), у бруцелл.

Выясняется роль этой регуляции в выживании бруцеллы при незавершённом фагоцитозе (бруцеллез). [Биофизика, в печати]

2.7 Статистические данные о расположении длинных спиралей в геномах Актинобактерий относительно кодирующих областей: длинные спирали концентрируются в некодирующих областях вблизи 3'-концов высоко экспрессируемых генов (включая тРНК) или между сходящимися навстречу друг другу генами. Выясняется роль таких шпилек в снятии конформационного напряжения ДНК и при терминации транскрипции путем образования крест-шпилек на ДНК. [МолБиол, 2007, 41(4)]

3. Найдены новые случаи известных типов регуляции у бактерий:

3.1 Предсказана белок-ДНКовая регуляция на уровне транскрипции и также промоторы генов [синтеза пролина](#) у [протеобактерий](#) родов *Pseudomonas* и *Shewanella*. [Молекулярная биология, 2007, 41(3)]

3.2 Предсказано много случаев [белок-ДНКовой репрессии/активации](#). В частности, охарактеризован GlpR-регулон (регуляция метаболизма глицерол-3-фосфата). [Молекулярная биология, 2003, 37(5) – совместно с М.С. и его сотрудниками].

3.3 Проведен широкомасштабный поиск регуляции на уровне транскрипции посредством Т-боксов.
[Молекулярная биология, 2005, 39(6)]

3.4 Предсказана классическая аттенюаторная регуляция:
(а) у протеобактерий (включая дельта-протеобактерии) и
у видов из таксономических групп бацилл/клостридий и
бактероидов [FEMS 2004], (б) у Актинобактерий [ВМС
Microbiology, 2005, 5:54]

3.5 Предсказана регуляция на уровне трансляции посредством тиаминового рибопереключателя для гена *ucoE*, кодирующего субъединицу ABC транспортёра: происходит перекрывание сайта связывания рибосомы иногда прямо черенком рибопереключателя, а иногда дополнительной спиралью РНК –

происходит быстрая смена этих механизмов регуляции у очень близких видов (показана эволюция этого механизма). [Информационные процессы, 2006, 6 (1)]

4. Белок-РНКовая регуляция в пластидах:

4.1 Корреляция сплайсинга с белок-РНКовой регуляцией трансляции в хлоропластах растений и водорослей.

[Journal of Bioinformatics and Computational Biology, 2006, 4, 4, 783; Биофизика, 2006, 51, тематический выпуск 1]

4.2 Связь вторичной структуры РНК с редактированием инициирующего кодона в хлоропластах у мхов и папоротников. [Биофизика, 2006, 51, тематический выпуск 1]

4.3 Найдена высоко консервативная регуляция экспрессии генов *psaA*, *psbA* и *psbB* (вне связи со сплайсингом) [Journal of Bioinformatics and Computational Biology, 2006, 4(4)].

4.4 Найдена ортологичная консервативная регуляция гена *ycf24* на уровне трансляции в пластидах красных водорослей и паразитов из таксона Apicomplexa (*Eimeria tenella*, *Plasmodium* spp., *Toxoplasma gondii*). Более того, у *T. gondii* эта регуляция охватывает и много других генов, включая те, которые кодируют РНК-полимеразу:

этот ген кодирует белок SufB, необходимый для формирования железосероцентров.

Выясняется роль пластид в жизни токсоплазм на молекулярном уровне. [Мол. биология, в печати]

5. Промоторы бактериального типа в пластидах и соответствующие им сигма-факторы у растений и водорослей:

5.1 Изучена быстрая эволюция промоторов перед геном *ndhF*, чья транскрипция у Резушки Таля (*Arabidopsis thaliana*) существенно зависит от сигма-субъединицы *Sig4*. [Физиология растений, в печати].

5.2 Предсказано, что кодируемая в ядре сигма-субъединица *Sig4* РНК-полимеразы бактериального типа существовала уже у предка высших двудольных растений и у него же имелся *Sig4*-зависимый промотор:

соответствующие кДНК *sig4* найдены по базе EST у винограда *Vitis vinifera* и двух видов апельсина *Citrus clementina* и *C. sinensis* (у апельсинов это псевдоген). Также известен псевдоген *sig4* у тополя *Populus trichocarpa*. А *Sig4*-зависимые промоторы предсказаны в хлоропластах у всех видов из таксона Eurosids II (включая крестоцветные, апельсин и хлопок), а также у нескольких далёких представителей двудольных: эвкалипта, винограда и платана.

5.3 Исследованы Sig3-зависимые промоторы перед геном *psbN* у семенных растений и показано общее! для всех однодольных растений значительное отличие области этого промотора от прочих цветковых растений.

5.4 Найдены высоко консервативные хлоропластные промоторы бактериального типа перед генами *rbcL*, *psaA*, *psbA*, *psbB*, *psbE* у большинства видов из Streptophyta.

Более того, промотор перед геном *psbA*, кодирующим белок D1 второй фотосистемы, **одинаков** у Streptophyta, включая рано отделившиеся роды *Mesostigma* и *Chlorocybus*, и у вторичного симбионта *Bigelowiella natans* из таксона Cercozoa.

5.5 Найдены промоторы перед геном *rps20* и близлежащие сайты связывания транскрипционного фактора (– ортолога NtcA) в хлоропластах красных и криптофитовых водорослей. При этом сайт для NtcA найден тогда и только тогда, когда дивергентно располагается ген *glnB*. У цианобактерий оба белка NtcA и GlnB вовлечены в регуляцию генов метаболизма азота и их взаимная регуляция показана (в частности, NtcA активирует транскрипцию *glnB*).

На этом основании предсказана регуляция в хлоропластах по механизму конкуренции РНК-полимераз, транскрибирующих гены на противоположных цепях ДНК, причем также происходит активация транскрипции *glnB*.

**6. Найдена общая белок-ДНКовая регуляция
экспрессии ядерных генов, кодирующих
рубредоксин и киназу,
фосфорилирующую белки по тирозину,
у диатомовой водоросли
Thalassiosira pseudonana и
у паразитов родов *Theileria* и *Babesia***

Эти виды являются вторичными симбионтами и имеют пластиды с общим происхождением от красных водорослей. Однако их ядерные геномы сильно отличаются. Поэтому можно предполагать связь этой регуляции с пластидами. Интересно, что киназы обычно участвуют в [регуляторных каскадах, передающих сигнал от некоторой мембраны, в частности, от пластиды.](#)

Пластиды у диатомовых водорослей и паразитов Apicomplexa похожи, а ядерные геномы значительно различаются. С другой стороны, у криптофитовых водорослей рубредоксин кодируется в нуклеоморфе, т.е. непосредственно связан с пластидами. Поэтому можно предположить, что эти очень близкие [регуляторные механизмы связаны с появлением пластид.](#)