



Уровни изучения генома



Регуляторные последовательности ДНК

Для изучаемой последовательности ДНК определяют:

- Сайты рестрикции для экспериментов по клонированию
- Сайты связывания транскрипционных факторов для понимания регуляции транскрипции гена
- Открытые рамки счтывания и аминокислотные последовательности, соответствующие им
- Для протяженных последовательностей определяют потенциальную экзон-инtronную структуру для поиска генов
- Вторичную структуру РНК – продуктов транскрипции генов
- Частоты использования кодонов в открытых рамках счтывания



Укладка ДНК и регуляция транскрипции

Хромосомы эукариот упакованы в хроматин, первым уровнем упаковки является нуклеосомный уровень

Нуклеосомы содержат гистоны, гистоны подавляют транскрипцию, поскольку конкурируют с регуляторными белками за связывание с ДНК

Установлено с помощью экспериментов по чувствительности к ДНК-азе I


- ДНК-аза I быстро расщепляет транскриционно активную ДНК
- Гистоны защищают ДНК от ДНК-азы I и быстрого расщепления не происходит
- Эксперименты по добавлению гистонов и регуляторных белков транскрипции показали, что гистоны конкурентно связываются с промоторами и подавляют транскрипцию

Решение «проблемы гистонов»:

Транскриционно активные гены имеют менее развитую структуру хроматина, чем неактивные гены

- Гистоны ацетилируются и фосфорилируются, изменяя способность связываться с ДНК
- Белки, связывающиеся с энхансерами, блокируют гистоны и

Укладка ДНК



Направления геномики

Анализ экспрессии генов

Изменения экспрессии во времени

Определение регуляторных районов

Функциональная классификация и рассмотрение ортологов

Сравнения геномов

Изучения семейств ортологов

Выявление и анализ часто встречающихся мотивов

Аннотация геномов

Построение деревьев сходств геномов


Структурная геномика

Предсказание генов и других элементов геномов

Направления биоинформатики



Схема структуры эукариотического гена




Регуляция гена

- Гены регулируются на уровне транскрипции регуляторными белками, которые связываются с сайтами ДНК, расположенными выше, ниже и в пределах последовательности гена
 - Промоторы
 - Энхансеры
 - Сайленсеры
 - Локус-контролирующие районы
- Гены регулируются:
 - Метилированием ДНК
 - Пост-транскрипционно мРНК-белковыми взаимодействиями
 - Пост-трансляционно белок-белковыми взаимодействиями

Промоторы

- РНК-полимераза связывается с ДНК промотора и базальным транскрипционным комплексом, и начинается транскрипция
- Регуляция транскрипции в ~~большой~~ степени связана с регуляторными элементами промотора




Транскрипция гена регулируется промоторами

Промоторы:

- Расположены выше точки старта транскрипции
- Содержат регуляторные элементы, определяющие (1) где находится точка транскрипции (например, ТАТА-бокс), (2) будет ли транскрипция (сайты связывания транскрипционных факторов)
- С сайтами, расположенными в пределах промоторов, связываются транскрипционные факторы.
- Для одного гена может быть один или несколько промоторов
- Промоторы могут содержать позитивные и негативные регуляторные элементы

Энхансеры и сайленсеры

Районы, расположенные более удаленно выше промотора содержат сайты связывания регуляторных белков, которые влияют позитивно или негативно на транскрипцию гена



Энхансеры

Находятся выше и ниже точки старта транскрипции.


- Регуляторные белки связываются со специфическими последовательностями энхансера; связывание определяется последовательностью ДНК.
- Могут формироваться петли ДНК, которые позволяют транскрипционным факторам связываться элементами энхансера.
- Взаимодействия регуляторных белков определяют, будет транскрипция активирована или подавлена.

Промоторы и энхансеры

- Некоторые регуляторные белки являются общими для промоторов и энхансеров, другие – специфичными.
- Каждый промотор и энхансер содержит специфичный набор сайтов связывания белков, определяющих уровень экспрессии.
- Уровень экспрессии регулируется взаимодействием позитивных и негативных регуляторных белков.
- Число комбинаций связывающихся с промоторами и энхансерами белков чрезвычайно велико.

Локус-контролирующие районы

“Локус-контролирующий район” регулирует множество генов, находящихся на удаленном расстоянии. Механизм неизвестен.



Характеристики, которые различаются у генов и другими районами ДНК

Характеристики гена:

- i. динуклеотидные, кодонные и дикодонные характеристики
- ii. Регуляторные районы
- iii. Точка старта транскрипции, сайты сплайсинга, сайты терминации транскрипции, другие сайты
- iv. Родственные гены: отношение числа неконсервативных к числу консервативных замен < 1 , мало делеций, инсерций, в основном длина кодирующей части кратна трем.

Характеристики районов ДНК, не содержащих гены:

- i. Много повторов
- ii. В течение эволюции: отношение числа неконсервативных к числу консервативных замен = 1, много инсерций, делеций, сдвигов рамки считывания.

Различия между прокариотами и эукариотами:

- Экспрессия прокариотических генов регулируется опероном, содержащим сайты связывания регуляторных белков.
- Экспрессия эукариотического гена также регулируется с участием регуляторных районов, содержащих сайты связывания регуляторных белков. Гены не объединены в цистроны.
- Экспрессия эукариотического гена носит более сложный характер – транскрипция проходит в ядре, трансляция в цитоплазме.
- Рассматривают два типа регуляции эукариотического гена:
 - Кратковременную регуляцию – гены «включаются» и «выключаются» в ответ на воздействия окружающей среды и потребности клетки.
 - Долговременную регуляцию – регуляцию экспрессии генов в течение онтогенеза, дифференциация клеток.

Различные уровни регуляции эукариотического гена




Экспрессия эукариотического гена регулируется следующими уровнями:

- 3. транскрипция
- 5. Процессинг РНК
- 7. Транспорт мРНК
- 9. Трансляция мРНК
- 11. Деградация мРНК
- 13. Деградация белка

Экспрессия прокариотического гена регулируется:


транскрипцией

Образование преинициаторного транскрипционного комплекса



Точка старта
транскрипции

преинициаторный транскрипционный комплекс



RNApol: РНК-полимераза

CTD : Карбоксильный терминальный домен

TFIID ₁₁: ТВР + 10 ТРВ-связанных факторов


TFIIB ₁: Одиночный пептид связывается после ТВР

TFIIF ₄: Стабилизирует комплекс ТВР-TFIIB-pol-III, необходимый для связывания ПЕ

TFIIE ₄: Помогает связыванию TFIIN

TFIIN ₉: Имеет каталитическую активность (геликазную и киназную)

* Число субъединиц





сайленсер

репрессор

Энхан-
сер

активатор

энхансер

активатор

активатор

РНК-полимераза


Кодирующая
последователь-
ность

TATA-бокс


кодовый
промотор

Транскрипционные факторы могут взаимодействовать друг с другом


- Регуляторные элементы эукариотических генов часто собраны в «модули»
 - Транскрипционные факторы часто действуют синергично (кооперативно)




Кепирование 5' пре-мРНК и элонгация транскрипции




Факторы сплайсинга связываются
с карбоксильным доменом РНК-пол II




Факторы 3'расщепления и полиаденилирования
связываются с карбоксильным доменом РНК-пол II



Сложное взаимодействие аппарата транскрипции и факторов процессинга мРНК



Спlicing нужен для эффективного транспорта мРНК в цитоплазму




Процессы, связанные с экспрессией эукариотического гена




Метилирование ДНК

- Нуклеотидное основание “С” может быть метилировано:



цитозин 5-метил-цитозин

- Это приводит к более плотной упаковке ДНК и ослаблению транскрипции:



Выравнивание 10 сильных промоторов генов бактерий и бактериофагов

Кодирующая
часть гена

GTGCGTG	TTGAC	TATTTA	CCTCTGGCGGT	GATAAAT	GG	TTGCA	A	TGTA	CTAAAGGA
GGCGGTG	TTGAC	ATAAATA	CCACTGGCGGT	GATAACT	GA	GCAC	A	TCA	GGCAGGACG
TGAGCTG	TTGAC	AAATTAA	CATCGAACTAG	TGTA	CTAG	TACCG	A	AGT	TCAACGTTAA
CCCAGGC	TTTAC	ACTTTAT	GCTTCCGGCTCG	TATGTT	GT	GTGG	A	ATTG	TGAGCGG
CCCAGGC	TTTAC	ACTTTAT	GCTTCCGGCTCG	TATAAAT	GT	GTGG	A	ATTG	TGAGCGG
ATCCCTAC	TTTAC	CTTTTAT	ATCGCGAACTCT	TGTA	TTTCCCGAT	ACCC	A	CCCG	TTTTTT
TTTCCCT	TTG	CGGGCCGG	AATAACTCC	CTATAAAT	GGCC	CC	A	CTGAC	ACGGAA
TAAATGC	TTGAC	CTGTAG	CGGGAAAGGCC	TATTAATG	C	ACACCC	C	CCCG	CGGCGA
TCCATGT	CAAC	CTTCGCGATCTT	TGATGCGT	ATGCGT	TA	TTTCA	A	TAC	CTAAAGCC
TTATTCC	ATGTC	ACACTTT	TGGCATCTTGT	TATGCTAT		GGTT	A	TTTC	CATACCAT

Consensus
sequence:

TTGAC

-35

GATAAAT

-10

+1

Промотор гена тимидин-киназы вируса герпес

+1



-105 **CCCCCCCCAGCGTCTTGTCA**TTCCC-81

-61 CAGTC**GGGGGGGGC**-48

-32 TTTCGCA**TATTAAGGT**-17

GC богатый элемент

CCAAT – GC богатый элемент
бокс

ТАТА бокс

Схема расположения регуляторных районов эукариотического гена

энхансер

промотор

Точка старта транскрипции(+1)

700-1000 п.о.

Структурный ген

- Промоторный район содержит регуляторные элементы, обычно расположенные на расстоянии около 100. п.о. от точки старта транскрипции, включающие: ТАТА-бокс (-25 –35 п.о.), СААТ-бокс (-70 –80 п.о.) и GC-бокс (примерно –110 п.о.)

- Другие регуляторные районы – энхансеры. Их расположение нестрого фиксировано относительно точки старта транскрипции. Они могут быть расположены выше, ниже и в пределах гена

GC бокс

GGGGGG

-110

CAAT бокс

GGCCAATC

-70


TATA бокс

ATATAAA


-30

Точка старта транскрипции(+1)

Сайты сплайсинга



Консенсусные последовательности сайтов сплайсинга позвоночных



Консенсус 5'сайта
сплайсинга

Консенсус точки
ветвления

Консенсус 3'сайта
сплайсинга

Функциональные сайты

- Функциональный сайт – наименьшая функциональная единица генома (также называемая функциональный мотив, сигнал)
- Комбинация функциональных сайтов составляет функциональный район
- Функциональной единицей белок-кодирующей последовательности является кодон.
- Различные функциональные сайты могут перекрываться и взаимодействовать
- Функциональные сайты могут присутствовать в кодирующих частях гена
- часто функциональные сайты являются сайтами связывания регуляторных белков

Функциональные сайты

Анализ и распознавание функциональных сайтов основано на поиске контекстных характеристик, общих для всех сайтов, выполняющих специфическую функцию

Функциональные сайты, как правило, характеризуются вариабельностью контекстных характеристик, что затрудняет создание точных методов распознавания.

Требования к выборке сайтов

- Для адекватного анализа выборки сайтов требуется гомогенность выборки (то есть сходство анализируемых структур сайтов)
- Гетерогенность выборки приведет к тому, что такие методы как консенсус и весовая матрица будут построены с усреднением различных характеристик и проявят низкую точность

Классификация сайтов сплайсинга

Одним из предложенных методов классификации сайтов сплайсинга является метод, строящий набор консенсусов. Он основан на следующих допущениях:

- Высокая частота определенных нуклеотидных оснований в определенных позициях сайта отражает функциональную важность этого нуклеотидного основания в данной позиции.
- Нуклеотидные основания в различных позициях сайтов могут быть взаимозависимы, формируя таким образом структуру, которую могут распознавать какие-либо факторы

Классификация сайтов сплайсинга

Предложенный метод классификации сайтов сплайсинга, строящий набор консенсусов, характеризуется недостаточной точностью распознавания сайтов сплайсинга. Для распознавания генов более важно не пропустить сайты сплайсинга, повышенная частота ложно-положительных предсказаний не играет негативной роли

Поли-А сайты

- Поли-А сайт, расположенный ниже экзон-богатого района является хорошим свидетельством в пользу того, что нуклеотидная последовательность содержит ген, который завершает кодирующую часть найденным поли-А сайтом
- Предсказание поли-А сайтов в настоящее время характеризуется низкой точностью и дает много ложно-положительных и ложно-отрицательных предсказаний

Поли-А сайты

- Наиболее известный вариант поли-А сайта имеет вид ААТААА, расположен на 15-20 п.о. выше точки расщепления РНК и присоединения поли-А хвоста
- Около 90% РНК содержат точную копию этой последовательности. Другой часто встречающийся вариант АТТААА
- Анализ соседних оснований показал, что некоторые другие основания могут быть важны для распознавания поли-А сайта.
- Выявлен дополнительный сигнал YGTGTTYY на расстоянии 20-30 п.о. ниже сайта расщепления РНК

Районы прикрепления к ядерному матриксу

Районы прикрепления к ядерному матриксу связаны с сайтами, которые регулируют экспрессию генов. Пример программы поиска этих районов:

www.ncgr.org/MarFinder

Островки CpG

- На 5' конце около половины генов млекопитающих расположен островок CpG
- Предполагают, что на 5' конце всех генов домашнего хозяйства млекопитающих расположен островок CpG
- Наличие CpG островков рядом с генами других позвоночных не столь постоянно

Островки CpG и структура генома

- Первичная структура генома очень гетерогенна. Наиболее известным примером такой гетерогенности являются островки CpG.
- Островки CpG составляют специфическую фракцию генома и, в отличие от большей части ДНК, они неметилированы и характеризуются повышенным содержанием CpG
- Островки CpG характеризуются значительно повышенным содержанием C:G по сравнению с остальной ДНК. Островки CpG могут служить маркерами генов
- В гаплоидном геномме человека присутствует около 45 000 островков CpG

Сайты связывания транскрипционных факторов

- Белок-кодирующие гены эукариот транскрибируются РНК-полимеразой II. Транскрипция инициируется на промоторном районе с участием комплекса различных факторов.
- Элементарные регуляторные сигналы короткие (5-30 п.о.) и очень вариабельны.

Часто встречающимися сигналами промоторов генов, транскрибуемых РНК-полимеразой II, являются ТАТА-бокс, сайт кепирования, СААТ-бокс, GC-бокс. ТАТА-бокс присутствует в большинстве промоторных районов белок-кодирующих генов.

Методы распознавания функциональных сайтов

- консенсусные последовательности
- Весовые матрицы
- решающие деревья
- Скрытые марковские модели (Hidden Markov Models, HMMs)
- Нейронные сети
- другие

Пример консенсусной последовательности

- В самом простом случае в каждую позицию консенсуса ставится наиболее часто встречающееся нуклеотидное основание в 4- или 15-буквенном коде

Консенсус может приводить к потере информации и к ложным предсказаниям

consensus sequence

consensus (IUPAC)

TACGAT

TATAAT

TATAAT

GATACT

TATGAT

TATCTT

TATAAT

TATRNT

MELON

MANGO

HONEY

SWEET

COOKY

MONEY

Пример (позиционной) весовой матрицы

- Computed by measuring the frequency of every element of every position of the site (weight)

TACGAT
TATAAT
TATAAT
GATACT
TATGAT
TATGTT



	1	2	3	4	5	6
A	0	6	0	3	4	0
C	0	0	1	0	1	0
G	1	0	0	3	0	0
T	5	0	5	0	1	6

- Вес потенциального сайта определяется как сумма весов матрицы, типу основания в каждой позиции потенциального сайта
- Недостатки:
 - Требуется пороговое значение веса
 - Предполагает независимость встреч оснований в позициях

Пример частотной матрицы ТАТА-бокса

Posi- -3 -2 -1 0 +1 +2 +3 +4 +5 +6 +7 +8 +9 +10 +11

Пози-
ции
(a)

A	16	4	90	1	91	69	92	57	40	14	21	21	21	17	20
C	37	12	0	2	0	0	1	1	11	35	38	33	30	28	26
G	39	5	1	1	1	0	5	11	40	39	33	33	33	36	36
T	8	79	9	96	8	31	2	31	9	12	8	13	16	19	18

(b)	G	T	A	T	A	A	A	A	G	G	C	G	G	G	G
	C	T	T	T	T		T	A	C	G	C	C	C	C	C

Пример частотной матрицы сайта, содержащего инициаторный кодон

Позиции	Нетранслируемый район									Кодирующая последовательность	
	-6	-5	-4	-3	-2	-1	+1	+2	+3		
G	C	C	A	C	C	A	T	G			
A	18	19	24	68	23	15	100	0	0		
C	21	40	58	2	55	53	0	0	0		
G	47	23	12	30	16	23	0	0	100		
T	13	18	6	0	7	9	0	100	0		

Пример частотной матрицы сайта, содержащего инициаторный кодон

Пози- -3 -2 -1 +1 +2 +3 +4 +5 +6
ции

A	28	59	8	/	0	0	54	74	5	16
C	40	14	5	/	0	0	2	8	6	18
G	17	13	81	/	100	0	42	11	85	21
T	14	14	6	/	0	100	2	8	4	45

A	G	/	G	T	R			
G	/	G	T	N	A	G		
	/	G	T	R	A	G		
	/	G	T	R	N	G	T	
G	/	G	T	A				


Акцепторные сайты сплайсинга

Пози -ции	инtron													экзон			
	-14	-13	-12	-11	-10	-9	-8	-7	-6	-5	-4	-3	-2	-1	/	+1	
T	T	T	T	T	T	T	T	T	T	N	C	A	G	/	G		
A	10	8	6	6	9	9	8	9	6	6	23	2	100	0		28	
C	31	36	34	34	37	38	44	41	44	40	28	79	0	0		14	
G	14	14	12	8	9	10	9	8	6	6	26	1	0	100		47	
T	44	43	48	52	45	44	40	41	45	48	23	18	0	0		11	

Пример решающего дерева

Все донорные сайты сплайсинга

A%	C%	G%	U%
33	36	19	13
56	15	15	15
9	4	78	9
44	3	51	3
75	4	13	9
14	18	19	49
34	37	18	11
59	10	15	16
40	4	53	3
70	4	16	10
17	21	21	42
37	42	18	3
39	5	51	5
62	5	22	11
19	20	25	36
32	40	23	5
27	4	59	10
51	5	25	19



Pos	A%	C%	G%	U%
-3	35	44	16	6
-2	85	4	7	5
-1	2	1	97	0
+3	81	3	15	2
+4	51	28	9	12
+6	22	20	30	28
-3	29	31	21	18
-2	43	30	17	11
+3	56	0	43	0
+4	93	2	3	3
+6	5	10	10	76
-3	29	30	18	23
+3	42	1	56	1
+4	80	4	8	8
+6	14	21	16	49
-3	39	43	15	2
+3	46	6	46	3
+4	69	5	20	7

Все сайты

ПОЗИЦИЯ

Base	-3	-2	-1	+1	+2	+3	+4	+5	+6
------	----	----	----	----	----	----	----	----	----

A%	33	60	8	0	0	49	71	6	15
----	----	----	---	---	---	----	----	---	----

C%	37	13	4	0	0	3	7	5	19
----	----	----	---	---	---	---	---	---	----

G%	18	14	81	100	0	45	12	84	20
----	----	----	----	-----	---	----	----	----	----

U%	12	13	7	0	100	3	9	5	46
----	----	----	---	---	-----	---	---	---	----

мЯРНК

3'

G

U

C

C

A

U

U

C


A

5'

Распознавание сайтов сплайсинга в кДНК

- Предсказание сайтов сплайсинга в лишенных инtronов кДНК важно для некоторых экспериментальных работ
- Сайты сплайсинга в кДНК состоят из экзонных частей донорного и акцепторного сайтов сплайсинга
- Поэтому консенсусной последовательностью для таких сайтов является MAG/G

Марковские модели



Составляющие марковской модели

- Набор состояний:
 $\{S_1, S_2, \dots, S_N\}$
- Вероятности переходов между состояниями
(матрица транзиций)

$$A_{ij} = P(q_{t+1} = S_i | q_t = S_j)$$

- Распределение начального состояния

$$\pi_i = P(q_1 = S_i)$$

Методы распознавания сайтов сплайсинга

- **Весовые матрицы** Staden, 1984, Shapiro and Senapathy, 1987, Senapathy et al., 1990; Zhang and Marr, 1993),
- **перцептрон** Nakata et al., 1985), quantification method (Iida, 1987; Iida, 1988),
- **learning technique** (Kudo et al., 1987); Quinqueton and Moreau, 1985),
- **Нейронные сети** (Brunak et al., 1991; Brunak et al., 1990; Lapedes et al., 1990),
- **K-tuple статистика** Bougueleret et al., 1988; Solovyev, 1993; kel et al., 1993),
- **Дискриминантная энергия** (Gelfand, 1989; Penotti, 1991).

Программы распознавания сайтов связывания транскрипционных факторов

- В настоящее время программы распознавания сайтов связывания транскрипционных факторов интегрированы с базами данных о сайтах связывания транскрипционных факторов, консенсусах, весовых матрицах

- SIGNAL SCAN (Prestridge, 1991),
- MATRIX SEARCH (Chen et al., 1995),
- ConsInspector (Frech et al., 1993) and MatInspector (Quandt et al., 1995).
- PromoterView
- (<http://www.itba.mi.cnr.it/tradat>)
- (<http://transfac.gbf-braunschweig.de>)
- (<http://www.gsf.de>).

Пример ДНК-белкового взаимодействия



Структуры белков

- **Первичная структура** – последовательность аминокислот
- **Вторичная структура** – локальная пространственная организация белка; короткие участки укладки – альфа-спиралы и бета-складки
- **Третичная структура** – пространственная структура белка – как отдельные альфа-спиралы и бета-складки соотносятся друг с другом в пространстве (собираются в домены)
- **Четвертичная структура** – белок может состоять более чем из одной полипептидной цепи

последовательности белков

Суперсемейство

Семейство

домен

Мотив

Сайт

Аминокислотный
остаток

Сложность ССТФ как объекта изучения

- 1) Консервативные и вариабельные участки в последовательности сайта
- 2) Число консервативных участков в сайте
- 3) Направление, в котором работает сайт.
- 4) Границы и локализация консервативных участков.
- 5) Оптимальная длина флангов.

Определение локализации кора. Пример – выборка сайтов связывания SF-1

atgtcaaggccgtgac

atgt**CAAGGCCG**tgac

aggctcaaggtcatca

aggct**CAAGGTCA**tca

tcaaggagaaggtcag

tcaagga**GAAGGTCA**g

aaagttagaggtcagga

aaagt**AGAGGTCA**gga

gaggcaaggccactgg

gagg**CAAGGCCA**ctgg

taccaaggtcagaaat

tac**CAAGGTCA**gaaat

gagttcaaggtaataa

gagtt**CAAGGTAA**taa

tttcgaggtcatggcc

ttt**CGAGGTCA**tggcca

gacttcaaggcccua

gactt**CAAGGTCC**caa

cccccccaaggcccatg

aaaaa**CAACCCCC**atg

Подбор направлений последовательностей в выборке. Пример – выборка сайтов связывания SF-1

caggccaaaggtaaaa

c

gtagttcaaggcaat

a

ctcctaaggcatcc

t

aaattaccttgacca

c

caggc**CAAGGT**caaac

gtagtt**CAAGGC**aata

ctcc**TAAGGC**catcct

gtgg**CAAGGT**aattt

ggcac**CAAGGC**tagag

Поиск консервативных участков в последовательностях выборки. Матрица частот оснований для выборки сайтов SF-1

A	9	16	7	6	2	35	39	0	0	3	4	26	7	11	7	9	3
C	8	10	7	13	33	2	1	0	0	10	28	7	12	7	5	8	1
T	8	3	7	19	0	0	0	0	26	8	4	10	7	11	3	3	
G	9	9	19	2	5	4	1	41	41	2	1	4	12	14	15	3	0
	a	a	g	t	c	A	A	G	G	T	c	a	c	g	g	a	a

Коровый район

Оценка χ^2 для колонки весовой

W_a, W_c, W_t, W_g – абсолютные частоты оснований в данной позиции


p_a, p_c, p_t, p_g – относительные частоты нуклеотидных оснований в геноме

$$N = N_a + N_c + N_t + N_g$$

$$E_a = N \times p_a$$

$$\chi^2 = \frac{(N_a - E)^2}{E_a} + \frac{(N_c - E)^2}{E_c} + \frac{(N_t - E)^2}{E_t} + \frac{(N_g - E)^2}{E_g}$$

**Подбор консервативных участков в
последовательностях выборки. Оценки величины хи-
квадрат по матрице, построенной для выборки сайтов
SF-1**



i	a	g	t	C	Z	Z	C	C	T	C	Z	C	C	a	a
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Резюме

При построении частотной матрицы для сайтов, нужно определить:


- 1) 1) направление каждого сайта
- 2) 2) число и локализацию консервативных участков в каждом сайте, выравнивание сайтов
- 3) 3) оптимальные фланги, окружающие консервативные районы
- 4) 4) Пороговое значение веса последовательности для поиска сайтов

Задачи, возникающие при построении метода распознавания

- 1) Процедура «взвешивания»
последовательности (приписания
последовательности числа).
- 2) Получение порога для разделения
позитивной выборки от негативной.
- 3) Оценка точности метода на контроле

Построение метода распознавания сайтов

саггс**сааггт**сааас



Оценка веса последовательности с помощью весовой матрицы

A	W11	W12	W13	W14	W15	W16	W17	W18
C	W21	W22	W23	W24	W25	W26	W27	W28
G	W31	W32	W33	W34	W35	W36	W37	W38
T	W41	W42	W43	W44	W45	W46	W47	W48

**Весовая
Матрица**

C	A	A	G	G	C	C	G
----------	----------	----------	----------	----------	----------	----------	----------

**Тестовая
последоват
ельность**

Вес тестовой последовательности равен:

$$W(X) = \sum_{j=1,..L} W(a_j, j)$$

где a_j – нуклеотидное основание тестовой последовательности в позиции j .

Способы построения весовой матрицы

N_{ij}

Матрица абсолютных частот, $i=1,2,3,4$ – номера нуклеотидных оснований, $j=1,2,3,\dots,L$, где L – длина матрицы

$$F_{ij} = \frac{N_{ij}}{N}$$

Матрица относительных частот. N – число сайтов в выборке

$$W_{ij} = \log \frac{F_{ij}}{P_i}$$

Весовая матрица, которая максимально разделяет выборку сайтов от выборки случайных последовательностей, имеющих частоты оснований P_i $i=1,2,3,4$ (номера нуклеотидных оснований)

$$W_{ij} = F_{ij} \times \log \frac{F_{ij}}{P_i}$$

Информационная матрица

$$W_{ij} = \log \frac{F_{ij}}{F_{\max,j}}$$

Матрица дискриминантной энергии Берга-von Хиппеля. Максимальная энергия сайта равна нулю. Сайты с отклонением от консенсусной последовательности имеют энергию меньше нуля.

Построение метода распознавания сайтов

Негативная выборка :

```
tcccaagtgcgt  
acagtcgttagc  
gggtcgtcgaa  
ggtacgaaacga  
acagtgcgtca
```

Позитивная выборка:

```
taccaaggta  
agacaaggta  
ggacaaggta  
ggccaaggta  
agacaaggta
```

метод

метод





Схема разделения распределения весов сайтов от распределения весов случайных последовательностей



Площадь S_1 , оценка ошибки первого рода


Площадь S_2 , оценка ошибки второго рода

Распределение весов W_{Rnd}
для случайных
последовательностей

Распределение весов W_{site}
реальных сайтов

Значение веса W ,
выбранное для
разделения
распределений W_{site} и
 W_{no} .

Оценка разделения распределения весов сайтов от распределения весов случайных последовательностей



A – число негативных последовательностей, вес которых меньше порога

B – число сайтов, вес которых меньше порога

C – число негативных последовательностей, вес которых выше порога

D – число сайтов, вес которых выше порога

$$CC = \frac{A \times D - B \times C}{\sqrt{(A+C)(A+B)(C+D)(B+D)}}$$

Некоторые способы оценки точности распознавания

$$E_1 = \frac{N_{site}^-}{N_{site}}$$

Оценка ошибки первого рода (доля сайтов, которые не были распознаны)

N_{site}^- - число распознанных сайтов из контрольной выборки

N_{site} - размер контрольной выборки сайтов

$$E_2 = \frac{N_{no}^+}{N_{no}}$$

Оценка ошибки второго рода (доля негативных последовательностей, которые были распознаны как сайты)

N_{no}^+ - число негативных последовательностей, распознанных как сайты

N_{no} - размер контрольной выборки негативных последовательностей

Некоторые способы оценки точности распознавания

		Предсказание		
		сайты	не-сайты	
Р е а л ь	с	TP	FN	TP – число верно предсказанных сайтов,
	и			TN – число верно предсказанных негативных последовательностей (не-сайтов),
н о с т ь	н	FP	TN	FN – число неверно предсказанных сайтов,
	е			FP – число неверно предсказанных не-сайтов.

Некоторые способы оценки точности распознавания

В этих обозначениях оценка ошибки первого рода:

$$E_1 = \frac{FN}{FN + TP}$$

Оценка ошибки второго рода:

$$E_2 = \frac{FP}{TN + FP}$$

Некоторые способы оценки точности распознавания

Чувствительность – доля правильно предсказанных сайтов:

$$Sn = \frac{TP}{TP + FN}$$

Специфичность (доля правильно отвергнутых негативных последовательностей):

$$Sp = \frac{TP}{TP + FP}$$

Другое определение специфичности (это вероятность того, что предсказанный методом сайт действительно является сайтом):

$$Sp = \frac{TP}{TP + FP}$$

Коэффициент корреляции (мера связи между предсказанными и реальными объектами, одновременно учитывая все элементы таблицы сопряженности)

$$CC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FN)(TN + FP)(TP + FP)(FN + TN)}}$$


Точность предсказания

- Функциональная аннотация последовательностей в основном рассматривает два набора данных:
- Набор последовательностей, несущих функцию
- Набор последовательностей, не выполняющих данную функцию
- Каждый набор последовательностей нужно разбить на обучающую и контрольную выборку
- Контрольные выборки следует использовать только для оценки точности

Проблемы, возникающие при оценке точности предсказания

- **Базы данных о нуклеотидных последовательностях сильно вырождены (гомологи, повторы последовательностей)**
- **Нужно следить за тем, чтобы последовательности в обучающей и контрольной выборке были негомологичны**
- **Исключение гомологов сокращает размер выборки**
- **Разработан ряд критериев оценки точности, из которых следует выбрать подходящий для решения конкретной биологической задачи.**

Поиск сайтов связывания фактора SF-1 вдоль последовательности регуляторного района P00121 из TRRD



Name	Position	Strand	Site
SF-1	25	+	gccttagcgccag
SF-1	109	+	gaccagaggag
SF-1	138	+	tgtcaaggccg

Следующий шаг после анализа последовательности

Более полное
понимание
функции гена

Протеомика,
анализ
экспрессии,
структурная
геномика,
белок-белковые
взаимодействия

Изучаемые
гены,
расположение в
геноме

