

ВВЕДЕНИЕ В БИОИНФОРМАТИКУ

Лекция №7


Значимость выравнивания. Экспресс-сравнение последовательностей (BLAST). Построение и визуализация профилей множественных выравниваний.

Новоселецкий Валерий Николаевич
к.ф.-м.н., доц. каф. биоинженерии
valery.novoseletsky@yandex.ru

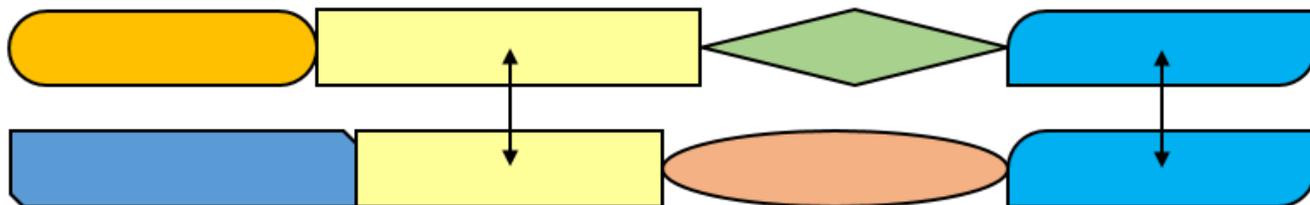
Сайт курса <http://intbio.org/bioinf2018>

Расчет выравнивания двух последовательностей

- Алгоритм Нидлмана-Вунша (1970) для глобального выравнивания
- Алгоритм Смита-Уотермана (1981) для локального выравнивания



Global Alignment



Local Alignment

Значимость выравнивания

Насколько значимо полученное выравнивание?

Имеет ли оно биологический смысл или образовалось случайно?

```
SEQUENCE 1 VLSAADKTNVKAAWSKVGGHAGEYGAEALERMFLGFPTTKTYFPHFDSLH 50
          |||.|||||.|||.|||||.|||||.|||||.|||||.|||||.
SEQUENCE 1 VLSPADKTNVKAAWGKVGHAHAGEYGAEALERMFLSFPTTKTYFPHFDSLH 50

SEQUENCE 51 GSAQVKAHGKKVADGLTLAVGHLDDLPGALSDLSNLHAHKLRVDPVNFKL 100
          |||||.|||||.||.||. |:|:|.|||. |:|||||.|||||.
SEQUENCE 51 GSAQVKGHGKKVADALTNVAHVDDMPNALSALSDLHAHKLRVDPVNFKL 100

SEQUENCE 101 LSHCLLSTLAVHLPNDFTPAVHASLDKFLSSVSTVLTSKYR 141
          |||||.|||.|||. :|||||.|||||. :|||||.|||||.
SEQUENCE 101 LSHCLLVTLAAHLPAEFTPAVHASLDKFLASVSTVLTSKYR 141
```

```
# Matrix: EBLOSUM62
# Gap_penalty: 10.0
# Extend_penalty: 0.5
#
# Length: 141
# Identity: 123/141 (87.2%)
# Similarity: 128/141 (90.8%)
# Gaps: 0/141 ( 0.0%)
```

Значимость выравнивания

```
SEQUENCE 1 -VLSEGEWQLVLHVWAKVEADVAGHGQDILIRLFKSHPETLEKFDRFKHL 49
          .|:|.:.|..|..|..|:..|.....|:..:..|... |.|..|
SEQUENCE 1 GALTESQAALVKSSWEEFNANIPKHTHRFFILVLEIAPAAK---DLFSFL 47
SEQUENCE 50 KTEAEM-KASEDLKKHGVTV-----LTALGAILKKKGHHEAELKP 88
          |..:|: :.:.|:..|...| |...|.:.: :|.|..
SEQUENCE 48 KGTSEVPQNNPELQAHAGKVFKLVEEAAIQLEVTGVVVT----DATLKN 92
SEQUENCE 89 LAQSHATKHKIPIKYLEFISEAIIHVLHSRHPGDFGADAQGAMNKALELF 138
          |...|.:.| .:..:..:..|:|:..:.. ..||.....:|.|.:.:
SEQUENCE 93 LGSVHVSK-GVADAHFPVVKEAILKTIKE---VVGAKWSEELNSAWTIA 137
SEQUENCE 139 RKDIAAKY-KELGYQG 153
          ..:|.:. |:..
SEQUENCE 138 YDELAIVIKKEMDDAA 153
```

```
# Matrix: EBLOSUM62
# Gap_penalty: 10.0
# Extend_penalty: 0.5
#
# Length: 166
# Identity:      35/166 (21.1%)
# Similarity:   62/166 (37.3%)
# Gaps:         26/166 (15.7%)
```

Значимость выравнивания



Кашалот




Люпин

Последний общий предок жил около 1 млрд лет назад!

Что общего между ними сейчас?


Значимость выравнивания

Title: 1MBN
PDB ID: 1MBN



Миоглобин кашалота (1mbn, 1969)

Title: 1GDJ
PDB ID: 1GDJ



Леггемоглобин люпина (1gdj, 1995) (ИК РАН)

What about Impossible Burger?



<https://impossiblefoods.com/>


Экспресс-методы сравнения последовательностей.

FASTA

FASTA (Lipman and Pearson, 1985, Pearson and Lipman, 1988) предназначен для сравнения новых последовательностей с уже содержащимися в базах данных.

Алгоритм:

- Поиск идентичных k -буквенных слов ($k = 2$ для белков, 4-6 для нуклеотидов, 1 для коротких последовательностей) между последовательностями;
- Расширение точек идентичности до областей сходства с использованием матриц замен (**BLOSUM50** для белков, **единичная** для нуклеотидов);
- Переоценка выявленных областей сходства с помощью целевой матрицы замен, определение 10 областей с максимальной оценкой;
- Перебор возможных вариантов построения выравнивания с использованием этих областей и выбор оптимального с учётом оценок областей и штрафов за вставки;



FASTA и FASTQ форматы

Исходно – формат представления последовательностей для программы FASTA.

```
>sp|P69905|HBA_HUMAN Hemoglobin subunit alpha OS=Homo sapiens...
MVLSPADKTNVKAAWGKVGAHAGEYGAEALERMFLSFPTTKTYFPHFDLSHGSAQVKGHG
KKVADALTNVAHVDDMPNALSALSSDLHANHLR...
```

FASTQ - обобщение формата FASTA.

```
@SEQ_ID
GATTTGGGGTTCAAAGCAGTATCGATCAAATAGTAAATCCATTTGTTCAACTCACAGTTT
+
!''*(((((***+))%%%++)(%%%) .1***-+*''))**55CCF>>>>>CCCCCCC65
```

Качество прочтения $Q(\text{sanger}) = -10 \log_{10}(e)$,
где e – вероятность **ошибочного** прочтения

94 градации в формате **ASCII**:

```
!"#$%&'()*+,-./0123456789:;<=>?@ABCDEFGHIJKLMNPO
QRSTUVWXYZ[\]^_`abcdefghijklmnopqrstuvwxyz{|}~
```

American Standard Code for Information Interchange (1967 - 2007)

ASCII Code Chart

	0	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F
0	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2		!	"	#	\$	%	&	'	()	*	+	,	-	.	/
3	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5	P	Q	R	S	T	U	V	W	X	Y	Z	[\]	^	_
6	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7	p	q	r	s	t	u	v	w	x	y	z	{		}	~	DEL

128 символов ($256 = 2^8$ в расширенной версии), так что для кодирования необходим **1 байт на 1 символ** (команду или знак).

Кодировка ASCII заменена на Unicode (в настоящее время содержит 137 439 символов, охватывающих 146 современных и исторических шрифтов, математические символы, эмодзи и т.д.)


Экспресс-методы сравнения последовательностей. BLAST

BLAST - **B**asic **L**ocal **A**lignment **S**earch **T**ool ([Altschul et al.,1990](#)) предназначен для сравнения новых последовательностей с уже содержащимися в базах данных.

Алгоритм:



- Удаление малоинформативных участков последовательности (повторы и т.п.);
- Составление списка k -буквенных слов (K-tuple), присутствующих в последовательности запроса;
- Сопоставление этих слов со всеми возможными словами длины k и оценка сходства; отбор слов с оценкой, превышающей пороговую (например, для слова PQG сходными будут PNG, PEG и PDG, но не PQW)
- Сканирование последовательности из БД и поиск в ней слов с высокой оценкой, полученных на предыдущем шаге;

Query sequence: PQGEFG



Экспресс-методы сравнения последовательностей. BLAST

- Расширение локальных выравниваний в обе стороны до тех пор, пока суммарная оценка выравнивания не начинает уменьшаться (построение сегментных пар (high-scoring segment pair, **HSP**));
- Объединение сегментных пар, лежащих на удалении меньше A ;
- Составление списка сегментных областей с высокой оценкой;
- **Расчет статистической значимости этих оценок.**



Бросание кубика

Рассмотрим бросание кубика n раз.
Каково математическое ожидание
числа N_l повторов длины l ?

$$E(N_l) = (n - l + 1)(1 - p)p^l \cong n(1 - p)p^l,$$

где p – вероятность выпадения грани

В случае наиболее длинного повтора $N = 1$. Тогда для
мат. ожидания длины L этого повтора справедливо

$$1 \cong n(1 - p)p^{E(L)} \Rightarrow E(L) = \log_{1/p} n(1 - p)$$

(Erdős, Rényi, 1970)(?)



Альфред Реньи
(1921 – 1970)

Бросание кубика

Точечная матрица – двумерное обобщение бросания кубика с заменой вероятности выпадения грани на вероятность совпадения букв.

Для последовательностей длиной n и m имеем

$$E(N) = (n - l + 1)(m - l + 1)(1 - p)p^l \cong mn(1 - p)p^l,$$

где p – вероятность совпадения

Более точное рассмотрение дает для мат. ожидания длины двумерного повтора выражение

$$E(L) = \log_{1/p}(mn) + \log_{1/p}(1 - p) + \gamma \log_{1/p} e - \frac{1}{2}$$

где «гамма» (постоянная Эйлера) $\approx 0,577215\dots$

$$\gamma = \lim_{n \rightarrow \infty} \left(\sum_{k=1}^n \frac{1}{k} - \ln n \right) = \lim_{n \rightarrow \infty} \left(1 + \frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{n} - \ln n \right)$$

(1735 – Эйлер – 5 знаков, ... 1973 – Уотерман – 4879 знаков, ...)

Бросание кубика

Переходя к натуральному логарифму и вводя обозначения

$$\log_{1/p} (1-p) + \gamma \log_{1/p} e - \frac{1}{2} \equiv \log_{1/p} K, \quad \ln \frac{1}{p} \equiv \lambda$$

Получаем

$$E(L) = \frac{\ln(Kmn)}{\lambda}$$

Аналогичное справедливо ([Karlin, Altschul, 1990?](#)) и для максимальной оценки $S_{n,m}$ сегментной пары (**HSP**), образованной последовательностями длиной n и m :

$$S_{n,m} \propto \frac{\ln(Kmn)}{\lambda}$$

Нормализация


$$\tilde{S}_{n,m} = S_{n,m} - \frac{\ln(Knm)}{\lambda}$$

BLAST. Значимость выравнивания


Распределение нормализованных максимальных оценок $\tilde{S}_{n,m}$ подчиняется распределению Гумбеля ([распределению экстремальных значений](#), [Gumbel, 1937](#); [Гнеденко, 1943](#)), для которого

$$P(\tilde{S}_{n,m} > S) \approx 1 - \exp(-K m n e^{-\lambda S}) \approx K m n e^{-\lambda S}$$

где S – случайная величина в интервале $(-\infty; +\infty)$ (но последнее приближение действительно только для больших S , когда $K m n * \exp(-\lambda S)$ мало!)



$$\varphi(x) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{x^2}{2}}$$



$$\varphi(x) = e^{-x} \cdot e^{-e^{-x}}$$


BLAST. Значимость выравнивания

$$P(\tilde{S}_{n,m} > S) \approx 1 - \exp(-K m n e^{-\lambda S}) \approx K m n e^{-\lambda S}$$

Но каковы в этом случае K и λ ? Прологарифмируем найденное выражение:

$$\ln(P(\tilde{S} > S)) = \ln(K m n) - \lambda S$$

Таким образом, мы можем построить много выравниваний для одной и той же последовательности запроса длиной n и базы данных суммарной длиной m (причем почти все эти выравнивания будут заведомо неправильными) и для каждого выравнивания поставить точку в координатах $(S, \ln(P(\tilde{S} > S)))$:



Получившиеся точки можно экстраполировать прямой по методу наименьших квадратов, а наклон этой прямой и её пересечение с осью ординат позволят определить K и λ .

BLAST. Значимость выравнивания

Для BLOSUM62 были получены значения $K = 0.040$ и $\lambda = 0.254$ (Altshul, Gish, 1996)(?).

Подставляем их в формулу для расчета вероятности:

$$P(\tilde{S}_{n,m} > S) \approx 1 - \exp(-K m n e^{-\lambda S}) \approx K m n e^{-\lambda S}$$

$$P(\tilde{S}_{n,m} > S) \equiv E - value$$

$E < 0,02$	высокая вероятность гомологии
$0,02 < E < 1$	гомология не очевидна
$E > 1$	сходство случайно

Пример (миоглобин кашалота):

```
>SP:MYG_PHYCD P02185 Myoglobin OS=Physeter catodon OX=9755 GN=MB PE=1
SV=2 Length=154
```

Score = 104 bits (259), **Expect = 1e-29**

Identities = 50/50 (100%), Positives = 50/50 (100%), Gaps = 0/50 (0%)

```
Query 1 LAQSHATKHKIPIKYLEFISEAIIHVLHSRHPGDFGADAQGAMNKALELF 50
LAQSHATKHKIPIKYLEFISEAIIHVLHSRHPGDFGADAQGAMNKALELF
Sbjct 90 LAQSHATKHKIPIKYLEFISEAIIHVLHSRHPGDFGADAQGAMNKALELF 139
```

BLAST. Значимость выравнивания

Для BLOSUM62 были получены значения $K = 0.040$ и $\lambda = 0.254$ (Altshul, Gish, 1996)(?).

Подставляем их в формулу для расчета вероятности:

$$P(\tilde{S}_{n,m} > S) \approx 1 - \exp(-K m n e^{-\lambda S}) \approx K m n e^{-\lambda S}$$

$$P(\tilde{S}_{n,m} > S) \equiv E - value$$

$E < 0,02$	высокая вероятность гомологии
$0,02 < E < 1$	гомология не очевидна
$E > 1$	сходство случайно

Другой пример (калиотоксин):


```
>lcl|PDB:1TI5_A mol:protein length:46 plant defensin Length=46
```

```
Score = 25.8 bits (74), Expect = 1.9
```


```
Identities = 12/31 (39%), Positives = 14/31 (45%), Gaps = 2/31 (6%)
```

```
Query 7 KCSGSPQCLKPCKDAGMRFGKC--MNRKCHC 35 калиотоксин
      KC      C      CK+ G      G C      M R C+C
Sbjct 12 KCLIDTTCAHSCKNRGYIGGNCKGMTRTCYC 42 дефензин
```

BLAST. Значимость выравнивания



калиотоксин



дефензин

```

3ODV_T  1  -GVEINV----KCSGSPQCLKPKKDAGMRFGKCM-N-RKCHCTPK-  38
1TI5_A  1  RTCMIKKEGWGKCLIDTTCAHSCKNRGYIGGNCKGMTRTCYCLVNC  46
          * :      ** . * : ** : *   * : *      * * : * :
    
```

```
>lcl|PDB:1TI5_A mol:protein length:46 plant defensin Length=46
```

Score = 25.8 bits (74), **Expect = 1.9**

Identities = 12/31 (39%), Positives = 14/31 (45%), Gaps = 2/31 (6%)

```

Query   7  KCSGSPQCLKPKKDAGMRFGKC--MNRKCHC  35  калиотоксин
          KC      C      CK+ G      G C      M R C+C
Sbjct  12  KCLIDTTCAHSCKNRGYIGGNCKGMTRTCYC  42  дефензин
    
```

Для коротких последовательностей сходство может быть НЕ случайным даже при $E > 1$!

Множественное выравнивание последовательностей

```

58 DEQTDIAAAYKITSLSLPTIVL-FEKGQEKHRAIGFMPKAKIVQLVVSQ--
58 DELGDVAQKNEVSAMPTLLL-FKNGKEVAKVVGANPAAI-KQAIAANA
58 DENPSTAAKYEVMСИPTLIV-FKDGQPVDKVVGFQPKENLAEVLDKHL
60 DDAQDVATHCDVKCMPTFQF-YKNGKKVQEFSGANKEKL-EETIKSLV
60 DDCQDVAAADCEVKCMPTFQF-YKKGQKVGEFSGANKEKL-EATITEFA
60 DDCQDVAAECEVKCMPTFQF-FKKGQKVDEFSGANKEKL-EATIKGLI
60 DDCQDVAAECEVKCMPTFQF-FKKGQKVSEFSGANKEKL-EATINELI
60 DDAQDVASHCDVKCMPTFQF-YKNNEKVHEFSGANKEKL-EEAIKKYM
60 DDCQDVASECEVKCMPTFQF-FKKGQKVGEFSGANKEKL-EATINELI
60 DDCQDVASECEVKCMPTFQF-FKKGQKVGEFSGANKEKL-EATINELV
60 DDCQDVAAECEVKCMPTFQF-FKKGQKVGEFSGANKEKL-EATINELI
60 DDCKDIAAACEVKCMPTFQF-FKKGQKVGEFSGANKEKL-EATINELL
60 DDCQDVASECEVKCMPTFQF-FKKGQKVGEFSGANKEKL-EATINELV
60 DDCQDVAAADCEVKCMPTFQF-YKKGQKVGEFSGANKEKL-EASITEYA
60 DDCQDVASECEVKCMPTFQFFFKKGQKVGEFSGANKEKL-EATINELV
* : . * . : . : * : . : : : . * :

```

Множественное выравнивание последовательностей

Цели:

- Построение филогенетических деревьев
- Выявление консервативных остатков и мотивов
- Построение профилей (визуализация)
- Итеративное выявление удаленной гомологии
- ...

Алгоритмы:


- **Динамическое программирование**
- Прогрессивное выравнивание
- Скрытые марковские модели
- Квантовые компьютеры?

Динамическое программирование

Прямой метод выполнения множественного выравнивания, обеспечивающий нахождение глобального оптимума.

Для выравнивания N последовательностей требуется построение N -мерной матрицы. Таким образом, пространство поиска растет экспоненциально с ростом N , а также зависит от длины последовательностей. Время поиска может быть оценено как $O(L^N)$.

A-BD-E-
ACB--E-
A--DCEE



Множественное выравнивание последовательностей

Цели:


- Построение филогенетических деревьев
- **Выявление консервативных остатков и мотивов**
- **Построение профилей (визуализация)**
- Итеративное выявление удаленной гомологии
- ...

Алгоритмы:

- **Динамическое программирование – не годится**
- Прогрессивное выравнивание
- Скрытые марковские модели
- Квантовые компьютеры?

Построение и визуализация профилей


Тиоредоксины – семейство белков, отвечающих за восстановление дисульфидных связей в белках и встречающихся как в животном, так и в растительном мире.



Выравнивание структур тиоредоксина человека и мушки *Drosophila melanogaster*.

Построение и визуализация профилей

(b)



s – число символов в алфавите (4, 20, ...)

$p(a, i)$ – вероятность появления буквы a в позиции i

Sequence logos: a new way to display consensus sequences (Schneider & Stephens, 1990)

$$H_i = - \sum_{\text{по всему алфавиту}} p(a, i) \log_2 p(a, i)$$

Шенноновская энтропия i -той позиции

$$R_i = \log_2 s - H_i$$

Информационная значимость i -той позиции

$$h(a, i) = p(a, i) R_i$$


Высота символа в профиле

Консенсусная последовательность и мотивы

Консенсусная последовательность – последовательность, в каждой позиции которой находится символ, наиболее часто встречающийся в данной позиции выравнивания.

Мотив – набор символов, (предположительно) имеющий биологическое значение.

$N\{P\}[ST]\{P\}$



Множественное выравнивание последовательностей

Цели:

- Построение филогенетических деревьев
- **Выявление консервативных остатков и мотивов**
- **Построение профилей (визуализация)**
- **Итеративное выявление удаленной гомологии**
- ...

Алгоритмы:

- **Динамическое программирование – не годится**
- Прогрессивное выравнивание
- Скрытые марковские модели
- Квантовые компьютеры?

Position-Specific Iterative BLAST

Position-Specific Iterative BLAST (**PSI-BLAST**) (Altschul et al. 1997)

<http://www.ebi.ac.uk/Tools/sss/psiblast/>

Алгоритм:

- Просмотр БД и составление списка последовательностей, сходных с последовательностью запроса;
- Расчет множественного выравнивания и набора позиционно-специфичных матриц замен (PSSM) для него;
- Новый просмотр БД с использованием полученных PSSM вместо стандартных матриц;
- Повторение процедуры либо желаемое число раз, либо до достижения сходимости (состояния, когда новые последовательности не обнаруживаются).



Давид Липман

EN = 3

PSI-BLAST эффективен при поиске удалённых гомологов.

Множественное выравнивание последовательностей

Цели:

- Построение филогенетических деревьев
- **Выявление консервативных остатков и мотивов**
- **Построение профилей (визуализация)**
- **Итеративное выявление удаленной гомологии**
- ...

Алгоритмы:

- **Динамическое программирование – не годится**
- **Прогрессивное выравнивание**
- **Скрытые марковские модели**
- Квантовые компьютеры?