

Поиск сигналов в последовательности ДНК

План


- Что такое сигнал — сайт связывания ТФ, и т. д. Сильные и слабые сайты?
- Умные слова мотив, паттерн, консенсус профиль
- БД мотивов — TransFac, JasPAR, RegTransBase
- Выявление и поиск мотивов (построение мотива по имеющимся данным и поиск нового мотива в последовательности):
 - НММ — требует большой объем данных
 - PFM/PWM — программа MEME

Сайты и белки



Painting published on cover of magazine: Nature Structural and Molecular Biology, September 1994, Volume 1 No. 9.

INTERFERON REGULATORY FACTOR 1



2pi0






Рисунок предоставлен О.Н. Занегиной

❖ ДНК-связывающие белки и их сигналы

□ Кооперативные однородные




□ Кооперативные неоднородные



□ Другие

Некоторые термины

- Мотив - сигнал, который есть у последовательностей, с которыми белок связывается и нет у последовательностей, с которыми белок не связывается.



- Профиль — способ отображения мотива, основанный на выравнивании




- Паттерн — вид профиля, в котором указываются все основания/аминокислоты, встречающиеся в данной позиции без указания частот

RRv nGAAASKGAAASK

- Консенсус — способ отображения мотива, в котором в каждой позиции указывается самое частое основание/аминокислота

GAAAGTGAAA

Для справки: Ambiguity codes



C/G/T (“не A”) → **B**

A/G/T (“не C”) → **D**



A/C/T (“не G”) → **H**

A/C/G (“не T”) → **V**

A/C/G/T → **N** (nucleotide)

Источник: РГМ

Исходные данные для поиска мотива (примеры)



- Данные экспериментов ChIP-Seq

- Upstream области коэкспрессирующихся генов

CCTACGCAAACGTTTTCTTTTT
GTCTCGCAAACGTTTGCTTTCC
CACACGCAAACGTTTTCGTTTA
TCCACGCAAACGGTTTCGTCAG
GCCACGCAACCGTTTTCTTTGC
GATACGCAAACGTGTGCGTCTG
CCGACGCAATCGGTTACSTTGA
GTTGCGCAAACGTTTTCTGTTAC

Методы обнаружения МОТИВОВ

Поиск точных последовательностей

Ищем подпоследовательности:

- которые часто встречаются в наборе последовательностей, связывающихся с белком, и
- не встречаются в контрольном наборе

Недостатки — ищет более-менее точное совпадение, в то время как большинство сайтов связывания ТФ устроены более сложно

Поиск мотива с использованием позиционно-весовой матрицы

Информационное содержание и энтропия Шеннона


$$H = - \sum_{i=1}^N p_i \cdot \log_2 (p_i)$$

где H — энтропия, p_i —
вероятность i -го события

Информационное содержание (I) —
мера уменьшения неопределенности
после получения некоторого
сообщения

$$I = H_{\text{before}} - H_{\text{after}}$$

Поиск мотива с использованием позиционно-весовой матрицы



Вес ($I(b_j)$) основания b в данной позиции j
 $I(b_j) = f(b_j) \log f(b_j) - p(b) \log p(b)$,
 где $f(b_j)$ — частота основания b в позиции j выравнивания, $p(b)$ — фоновая частота основания b

Вес позиции — сумма по столбцу,
 вес мотива — сумма весов позиций

Поиск мотивов программой MEME

Дано: длина искомого сигнала;
набор последовательностей, в которых ищется сигнал

1. Последовательно берем фрагмент заданной длины в каждой последовательности, ищем похожие фрагменты в других последовательностях, строим выравнивание. Берем базовые частоты букв из дополнения.
2. Для каждого выравнивания получаем PWM с максимальным весом, используя алгоритм EM (Expectation maximization)
3. Выбираем заданное число PWM с лучшим весом

Алгоритм EM (Expectation maximization)

- Строим PWM по выравниванию:
- По очереди удаляем фрагмент из выравнивания, и заменяем его на лучший по PWM фрагмент в соответствующей последовательности
- Находим максимальный вес, записываем PWM с максимальным весом

Ограничения MEME

1. Предположение о независимости позиций выравнивания
2. Находит мотив без гэпов
3. Последовательности должны быть как можно короче и содержать минимум шума
4. После 40 последовательностей, включение дополнительных последовательностей не улучшает работу алгоритма

From: **MEME Suite: tools for motif discovery and searching**

Nucleic Acids Res. 2009;37(suppl_2):W202-W208. doi:10.1093/nar/gkp335

TOMTOM OUTPUT	
Query File: ./output/tomtom_52109112_85850420/query.meme	
Target File: /www/tomcat/meme/db/motif_databases/macisaac_yeast.v1.meme	
Distance Measure: pearson	
All Motif Matches with <i>q</i> value at most: 0.5	
Target Motif: RGT1 Target Description: Query Motif: query Query Description: <i>p</i> -value: 0.00035 <i>q</i> -value: 0.087 Overlap: 6 Query Offset: 4 Orientation: + Figures: [EPS] [PNG]	
Total matches under <i>q</i> -value threshold: 0	
Command line:	<pre>/www/tomcat/meme/bin/tomtom -oc ./output/tomtom_52109112_85850420 -query ./output/tomtom_52109112_85850420/query.meme -target /www/tomcat/meme/db/motif_databases/macisaac_yeast.v1.meme -target-url-type macisaac -dist pearson</pre>

Figure Legend:

The figure shows the Tomtom output from searching a single DNA motif against a collection of yeast transcription factor binding site motifs identified via ChIP-seq (9). Tomtom shows that the query motif closely resembles the binding motif for transcription factor RGT1.

•

From: **MEME Suite: tools for motif discovery and searching**

Nucleic Acids Res. 2009;37(suppl_2):W202-W208. doi:10.1093/nar/gkp335

Sequence Analysis with fimo

Pattern Name	Sequence Name	Start	Stop	Score	p-value	q-value	Matched Sequence
1	NP_418484.4lyjcB	281	298	21.2367	5.3e-09	0.00758	AATTGTGATATAGTTCAC
1	NP_418485.1lyjcC	149	132	21.2367	5.3e-09	0.00758	AATTGTGATATAGTTCAC
1	NP_418031.1lyiaJ	175	158	19.8034	3.86e-08	0.0173	AAGTGTGCCGTAGTTCAC
1	NP_418032.1lyiaK	26	43	19.8034	3.86e-08	0.0173	AAGTGTGCCGTAGTTCAC
1	NP_418535.1lproP	37	54	19.7078	4.3e-08	0.0173	ATGTGTGAAGTTGATCAC
1	NP_414666.1lgcd	126	143	19.6123	4.85e-08	0.0173	AATTGTGATGACGATCAC
1	NP_414667.4lhpt	80	63	19.6123	4.85e-08	0.0173	AATTGTGATGACGATCAC

Figure Legend:

Полезные ссылки

- Анализ данных ChiPSeq
https://books.google.ru/books?hl=ru&lr=&id=YC2K_v1mficC&oi=fnd&pg=PA135&dq=makeev+vsevolod&ots=uSo84sL8A6&sig=xOTJH2RcPWhsjL7cBELQqkCkyfl&redir_esc=y#v=onepage&q=makeev%20vsevolod&f=true
- Bailey TL, Williams N, Misleh C, Li WW. MEME: discovering and analyzing DNA and protein sequence motifs. *Nucleic Acids Research*. 2006;34(Web Server issue):W369-W373. doi:10.1093/nar/gkl198.
- Tran NTL, Huang C-H. A survey of motif finding Web tools for detecting binding site motifs in ChIP-Seq data. *Biology Direct*. 2014;9:4. doi:10.1186/1745-6150-9-4.
- Kulakovskiy IV, Makeev VJ. DNA sequence motif: a jack of all trades for ChIP-Seq data. *Adv Protein Chem Struct Biol*. 2013;91:135-71.

Сравнение двух PWM

- Как в MEME
- Vorontsov et co-authors
<https://almob.biomedcentral.com/articles/10.1186/1748-7188-8-23>