

Межфакультетский курс «Биоинформатика»
Факультет биоинженерии и биоинформатики МГУ
осень 2014

Секвенирование

Платформы

Сборка

Сергей Александрович Спирин
15 и 22 октября 2014

История

- 1953: структура ДНК (Уотсон и Крик, Нобелевская премия 1962)
- 1973: опубликована первая последовательность природной ДНК: 24 п.н. (*Iac* оператор, Максам и Гилберт)
- 1977: опубликованы методы секвенирования Сэнгера и Гилберта (Нобелевская премия 1980)
- 1982: основан GenBank
- 1983: разработана полимеразная цепная реакция (ПЦР, PCR)
- 1987: первый автоматический секвенатор (Applied Biosystems Prism 373)
- 1995: первый геном бактерии (*Haemophilus influenzae*)
- 1996: капиллярный секвенатор ABI 310 (основан на методе Сэнгера)
- 1998: первый геном животного (круглого червя *Caenorhabditis elegans*)
- 2000: человеческий геном (почти полный)
- 2005: первый пиросеквенатор 454 Life Sciences (с 2007 – Roche): начало эры NGS
- 2006: первый секвенатор фирмы Solexa (с 2007 – Illumina)

Для чего

Геномы разных видов (бактерий, животных, растений)

Геномы индивидуумов (изучение индивидуальных различий)

Транскриптомы

ChIP-seq и подобные исследования

Секвенирование по Сэнгеру

Этапы:

выделение ДНК

подготовка «библиотеки»

амплификация (клонирование и ПЦР)

секвенирование «мечеными терминаторами»

Характеристики:

время работы несколько суток


длина прочтения («рида») до 1000 п.н.

один рид за раз

ошибки ~0,5%

Повторением части процедуры

(ПЦР+секвенирование) можно добиться ридов в несколько тысяч п.н. и почти исключить ошибки.



Секвенирование по Сэнгеру





Figure 1. An example of a DNA sequence tracing and the Phred score (grey bars) corresponding to each colored peak. The colored peaks on the trace correspond to each DNA letter. For

Платформа 454 Life Sciences (Roche)

Next Generation Sequencing : Amplified Single Molecule Sequencing Emulsion PCR™
different micro reactors : only 15 % are good ones



Этапы:

выделение ДНК

подготовка «библиотеки»

эмульсионный ПЦР

пиросеквенирование

Характеристики:


время работы 24 часа

длина рида 700 п.н.

число ридов 1 млн.

ошибки ~0,003%

The signal strength is proportional to the number of nucleotides incorporated



TCAG for signal calibration and normalization

Платформа Illumina (Solexa)

Этапы:

выделение ДНК

подготовка «библиотеки»

ПЦР «мостиками на подложке»

секвенирование «удаляемыми мечеными терминаторами»


Характеристики:

время работы 11 дней

длина рида 100 п.н.

число ридов 3 млрд.

ошибки ~0,1%



4 nucleotides with different dye
flow simultaneous



Top: CATCGT
Bottom: CCCCC

Случайное покрытие

Все платформы «второго поколения» включают подготовку **случайных** фрагментов генома и их амплификацию (размножение).

В результате риды также представляют собой набор случайных фрагментов заданной длины. В идеальном случае вероятность стать началом рида одинакова для всех позиций в геноме (а на практике это не всегда так).

Секвенирование «третьего поколения»

Ion Torrent: измеряется ток, возникающий при присоединении нуклеотида к растущей цепи (это перспективная технология, но скорее ещё «второго поколения», так как требует амплификации ДНК): риды 200 п.н., 1% ошибок, ~10 млн. ридов, несколько часов.

Helicos: пока риды ~35 п.н., 3% ошибок, 1 млрд. ридов, 8 дней. Появилась в 2009. Читается одна молекула! Тем самым не требуется амплификация. Это очень важно для, например, количественных исследований.

Pacific Bioscience: фиксируется удерживание нового нуклеотида на растущей цепи. Длина рида несколько тысяч п.н.! 70 000 ридов за полчаса, 5% ошибок.

Oxford Nanopore: цепь ДНК просачивается через нанопору, фиксируются характеристики проходящего нуклеотида. Риды длиной в десятки тыс. п.н.!!! Но пока ~20% ошибок.

Проблема сборки

Сборка на уже известный геном

(например, чтобы изучать различия между ДНК разных людей)

Сборка *de novo*

(например, хотим изучать геном вида, чей геном пока не секвенирован)

Сборка на геном

Пусть длина рида 100, размер генома 1 млн п.н. и мы получили 50 000 ридов.
Значит, среднее покрытие = 5. Хватит ли этого, чтобы собрать весь геном?

Сборка на геном

Пусть длина рида 100, размер генома 1 млн п.н. и мы получили 50 000 ридов. Значит, среднее покрытие = 5. Хватит ли этого, чтобы собрать весь геном?

Ответ: вряд ли. Риды ложатся случайно, примерно каждый 150-ый нуклеотид ими не покроеется. То есть почти наверняка более 6 000 нуклеотидов не будет покрыто, и при самой идеальной сборке получится не целый геном, а много кусков, разделённых непокрытыми участками.

При таком размере генома нужно не менее чем 15-кратное среднее покрытие, чтобы можно было рассчитывать собрать геном полностью!

Ещё проблема – повторы. Не всегда рид однозначно «ложится» на геном.

Третья проблема – время (при большом покрытии большого генома)

Сборка на геном

Главная проблема, решаемая разработчиками алгоритмов – время.
Два основных подхода: хэш-таблицы и суффиксные деревья.

Имеется несколько десятков программ, часть из них платные, часть – свободно распространяемые.

Сборка *de novo*

Есть два основных типа алгоритмов сборки:

- OLC = overlap-layout-consensus
- de Bruijn graph

Алгоритмы OLC работают непосредственно с ридями.

Алгоритмы, использующие граф де Брайна, сначала составляют список k -меров (слов длины k , например $k = 30$), встретившихся в ридях.

Недостатки:

теряется часть информации

Достоинства:

сильно экономится память (большинство k -меров встречается во многих ридях)

упрощается работа с повторяющимися участками

есть возможность отсеивать ошибки уже на начальной стадии

Алгоритмы сборки OLC

Программы: Phrap, Cap3, Tigr, ...

Read1 - TTTGGTGCTC TTCGAAAAGGGATC TTCGAGAGAGATC TC GCGATAAGGTTG

Read2 - GAGAGAGATC TC GCGATAAGGTTGAAGTAGAAAAATGTGTGTGGTGAA

overlap

TTTGGTGCTC TTCGAAAAGGGATC TTC**GAGAGAGATC TC GCGATAAGGTTG**
GAGAGAGATC TC GCGATAAGGTTGAAGTAGAAAAATGTGTGTGGTGAA

<http://www.homolog.us/Tutorials/Tut-Img/Set1/fig2.png>

Проблема повторов




Read1



Read2



Assembly



<http://www.homolog.us/Tutorials/Tut-Img/Set1/fig3.png>

Графы де Брайна


sequence

ATGGAAGTCGCGGAATC

7mers


ATGGAAG
TGGAAGT
GGAAGTC
GAAGTCG
AAGTCGC
AGTCGCG
GTCGCGG
TCGCGGA
CGCGGAA
GCGGAAT
CGGAATC

de Bruijn graph



Графы де Брайна


ATGGAAGTCGCG
GAGGAAGTCCTT




Графы де Брайна

Десятки программ: Velvet, ABySS, Trinity, Oases, SOAPdenovo, ...

NGS library



de Bruijn Graph



Genome



Результат сборки

Результат – так называемые «контиги», то есть непрерывные участки генома.

Для прокариот часто удаётся собрать весь геном (но редко «полностью автоматически» – обычно нужны дополнительные усилия, например секвенирование плохо покрытых участков по Сэнгеру).

Для эукариот, как правило, «геномом» объявляется свалка контигов, тем или иным способом приписанных к известным хромосомам.

Кроме контигов, бывают ещё «скаффолды» – последовательность контигов, между которыми остаются неизвестные участки (источник такой информации – особый приём секвенирования, называемый “pair-end read”)

Показатели качества сборки

Самый популярный – N50.

Это наибольшее число такое, что контигами длины $> N50$ покрыто 50% генома.

При этом чаще всего за длину генома принимают суммарную длину контигов.

Используется также N90 (аналогично – 90% генома).

Эта область биоинформатики очень молода, и удовлетворительные показатели ещё не выработаны!