

Сборка генома с помощью облаков ридов

Толстогоганов Иван Николаевич

научный руководитель: Банкевич Антон Викторович

СПб АУ НОЦНТ РАН

15 июня 2017 г.

- Поиск новых генов
- Обнаружение сложных вариаций
- Предсказание функции белка

Облака ридов: общее описание


Фрагменты



Геном

- ДНК разделяется на длинные фрагменты (до 50 килобаз)

Облака ридов: общее описание



- ДНК разделяется на длинные фрагменты (до 50 килобаз)
- Фрагменты секвенируются и баркодируются
- Из одного фрагмента формируется облако коротких ридов


Цель

Разработка алгоритма для сборки метагенома с помощью облаков ридов

Задачи


- Реализовать алгоритм в качестве дополнительного модуля к ассемблеру SPAdes
- Поддержать два наиболее распространённых протокола создания облаков ридов
- Сравнить эффективность алгоритма с альтернативными подходами на экспериментальных данных

Облака ридов: скаффолдинг




- Облако может быть восстановлено путем выравнивания на контиг
- Выравнивание используется для скаффолдинга

Граф де Брюйна



Облака ридов на графе де Брюйна



- Облака могут быть приложены и к рёбрам графа
- Для каждого длинного ребра мы хотим найти следующее в геномном пути
- Для этого используются облака ридов и структура графа



- Длинные рёбра в геномном пути могут быть расположены далеко друг от друга
- Пробелы могут быть закрыты после нахождения правильного порядка




- Длинные рёбра в геномном пути могут быть расположены далеко друг от друга
- Пробелы могут быть закрыты после нахождения правильного порядка
- Для закрытия используются пути из коротких ребер

- Используется простой метагеном из 10 организмов
- Референсы недоступны, вместо них используются:
 - 23 последовательности рибосомальных оперонов
 - Отдельные сборки каждого организма


Сборки были переданы в качестве референсов инструменту metaQUAST, предназначенному для оценки качества метагеномной сборки

Assembly	SPAdes	Athena	Architect	cloudSPAdes
# contigs	4333	3700	3989	3607
Total length	44454653	47352283	44467866	45282462
N50	70276	114821	153964	270900
# misassemblies	21	25	29	39
Genome fraction (%)	98.744	98.923	98.778	99.061
# N's per 100 kbp	0.00	0.00	?	127.14
Largest alignment	565835	503302	780028	1634993
NA50	44044	71261	76715	147448

- cloudSPAdes: Реализация алгоритма сборки с помощью облаков ридов на основе SPAdes
- Athena, Architect: Альтернативные инструменты для метагеномной сборки



NGA50 для каждого организма



Преимущества cloudSPAdes:


- Длинные контиги
- Восстановлено 22 оперона из 23, нашлось 9 НОВЫХ

Недостатки:

- Ошибки сборки в низкопокрытых геномах

- Разработан алгоритм сборки генома с помощью облаков ридов
- Алгоритм встроен в ассемблер SPAdes в качестве дополнительного модуля разрешения повторов
- Поддержаны протоколы создания облаков ридов TruSeq Synthetic Long Reads и 10XGenomics GemCode

Ошибки сборки



Полные результаты на GemCode

Assembly	SPAdes	cloudSPAdes	Architect	ARCS	Athena	FragScaff
# contigs	4333	3607	3989	4234	3700	4704
Largest contig	565922	1635422	1163531	565922	506140	1064532
Total length	44454653	45282462	44467866	44455643	47352283	60294921
N50	70276	270900	153964	87970	114821	87521
# misassemblies	21	40	29	62	27	365
Genome fraction (%)	98.745	99.061	98.776	98.750	98.964	98.839
# N's per 100 kbp	0.00	127.14	?	2.23	0.00	?
Largest alignment	565835	1634993	780028	565835	503302	618353
NA50	44044	147327	76715	47089	71261	18146

Результаты на TSLR

Assembly	Baseline	cloudSPAdes	Architect	FragScaff
# contigs	3657	3372	3407	3293
Total length	46637846	46894699	46683828	52366979
N50	78631	143747	191269	100994
# misassemblies	57	75	186	305
Genome fraction (%)	42.747	42.727	42.786	42.765
# N's per 100 kbp	9.40	624.58	18.31	10755.30
Largest alignment	739469	1311221	1240613	739469
NA50	77174	122883	126089	59381