

Домашнее задание – Практикум 11

Общая задача: поиск и аннотация вариантов одного человека по данным экзомного секвенирования на примере одной хромосомы

Задача практикума: подготовить необходимые файлы (парно-концевые прочтения и последовательность референсного генома), изучить качество предложенных чтений и проиндексировать референс.

1. Подготовка референса

Для себя лично и возможности восстановить картину происходящего в будущем настоятельно рекомендую сохранить команды подготовки референса и проверки качества чтений. Включать этап подготовки файлов и проверки качества чтений в программный сценарий (см. ниже) **не нужно!!!**

1) Получение референса

Создайте директорию для последовательности генома и индекса к программе для картирования с помощью hisat2, **скопируйте** в нее файл с вашей хромосомой. Теперь это ваш референс.

Индексация для hisat2

Проиндексируйте референсный геном (это ваша хромосома).

Мануал к hisat2 - <http://daehwankimlab.github.io/hisat2/manual/>

Команда для индексирования референса для последующего картирования:
hisat2-build chrN.fa prefix

При индексации референса можно использовать данные генной разметки, особенно при анализе RNA-seq, но сейчас мы этого делать **не будем**.

В данном случае prefix - префикс, с которого будут начинаться индексные файлы (должно получиться 8 файлов .ht2).

2) Индексация samtools

Многие программы перед работой с большими файлами требуют предварительной индексации согласно своим алгоритмам.

Одной из таких программ является **samtools**.

Индексирование: **samtools faidx chrN.fa**

На выходе должен получиться файл **chrN.fa.fai**

Описание можно прочитать тут:
<https://manpages.ubuntu.com/manpages/bionic/man5/faidx.5.html>

Из полученного **chrN.fa.fai** узнайте точное имя своей хромосомы и длину вашей хромосомы в нуклеотидах.

(*). Объясните каждую цифру из файла, полученного после индексирования референса с помощью samtools. В описании обратите внимание на раздел с примером, там все подробно описано.

2. Чтения ДНК

1) Описание образца

Найдите ID вашего образца в базе NCBI (<https://www.ncbi.nlm.nih.gov/>) в разделе SRA.

Укажите:

- a) SRR ID образца ДНК-чтений (см. ведомость)
- b) ссылку на информацию об образце из NCBI
- c) прибор для секвенирования
- d) организм
- e) стратегию секвенирования (полногеномное, экзомное, таргетная панель)
- f) парноконцевые или одноконцевые чтения
- g) сколько чтений ожидается (spots)

2) Проверка качества исходных чтений

Проанализируйте качество исходных чтений с помощью программы **fastqc**, исследуйте **оба (!!!)** файла (помните, что у вас парно-концевые чтения).
Мануал: <https://www.bioinformatics.babraham.ac.uk/projects/fastqc/>

Запустить **fastqc** можно с помощью команды **fastqc file.fastq.gz**

Программа умеет работать с архивированными файлами.

Не удаляйте получившиеся файлы (.html), они могут пригодиться на зачете.
Положите их туда, где можно **быстро взять**.

Укажите:

- a) какое количество пар чтений получилось
- b) совпадает ли количество чтений у “прямых” чтений и “обратных” чтений
- c) краткий комментарий качества пар чтений по результатам fastqc (картинка Per base sequence quality - 2 штуки(!))
- d) краткий комментарий о длине ваших чтений по результатам fastqc (картинка Sequence Length Distribution - 2 штуки(!))
- e) (*) краткий комментарий о любых других результатах fastqc. Помните, что на странице программы есть примеры для плохих и хороших чтений, а также подробно объяснено, что выдает программа

3) Фильтрация чтений

Вне зависимости от качества исходных чтений, проведите их фильтрацию с помощью **trimmomatic**.

Мануал: <http://www.usadellab.org/cms/?page=trimmomatic>

Обратите внимание, что на вход вы подаете 2 файла с чтениями, а на выходе получаете 4 файла (2 paired и 2 unpaired).

Программа запускается так: **TrimmomaticPE** ИЛИ **TrimmomaticSE**

Помните, что у вас парноконцевые чтения и -phred33.

Удалите с КОНЦА чтений нуклеотиды с качеством ниже 20 (без прохода окном!), оставьте только такие чтения, длина которых не ниже 50 нуклеотидов за одну команду. Параметры, которые не нужны для выполнения этих манипуляций, использовать **не нужно**.

Подумайте о том, почему после работы trimmomatic получается именно 4 файла и что содержится в каждом из них.

4) Проверка качества триммированных чтений

Проанализируйте качество чтений после обработки программой Trimmomatic (4 файла!!!) с помощью программы fastQC.

Укажите:

- a) какое количество пар(!) чтений осталось (paired) в штуках
- b) какой процент пар(!) чтений остался (paired) (процент от исходного количества пар чтений)
- c) краткий комментарий о сравнении качества чтений после(!) триммирования: paired vs unpaired
- d) краткий комментарий о сравнении качества чтений до и после триммирования (только paired)
- e) как изменилась длина чтений после триммирования?

5) (*) Сводный отчет о качестве чтений

Вы проанализировали качество чтений (исходных и после улучшения качества).

Для того, чтобы понять, что у вас все прошло хорошо, вам нужно было просмотреть несколько html файлов. И это только для одного образца.

Попробуйте разобраться с программой **multiqc**

<https://multiqc.info/>

С помощью этой программы можно собирать отчеты после работы разных программ, в том числе и fastqc.

Воспользуйтесь этой программой, чтобы собрать отчеты о качестве всех fastq файлах, которые были вами использованы при выполнении предыдущих пунктов задания.