

# Практикум 11

## Часть 1

### 1. Подготовка референса

#### **1) Индексация референса с помощью hisat2**

Для последующего картирования индексируем референсный геном, которым является 7 хромосома человека из референсной последовательности генома человека версии GRCh38.p14 (ensembl GCA\_000001405.29).

```
hisat2-build chr7.fa chr7
```

**Command:** hisat2-build – строит индексы (в нашем случае используя 32-битные числа) референсного генома

**Options:** chr7 – префикс имен выходных файлов

**Input:** chr7.fa – имя fasta-файла с референсным геномом

**Output:** chr7.1.ht2, chr7.2.ht2, chr7.3.ht2, chr7.4.ht2, chr7.5.ht2, chr7.6.ht2, chr7.7.ht2, chr7.8.ht2

#### **2) Индексация референса с помощью samtools**

Особая индексация референса необходима для некоторых программ.

```
samtools faidx chr7.fa
```

**Command:** samtools

**Options:** faidx – обеспечивает доступ к fasta (и fastq) файлам в input

**Input:** chr7.fa - имя fasta-файла с референсным геномом

**Output:** chr7.fa.fai

**В файле:** 7 159345973 56 60 61

**Точное имя хромосомы:** 7

**Длина хромосомы в нуклеотидах:** 159345973

**56:** индекс байта, с которого начинается сама нуклеотидная последовательность в fasta (в input) (то есть до самой последовательности находится 55 байтов, соответствующие, имени хромосомы и другим данным в первой строке после > )

**60:** длина строки fasta (в input) в нуклеотидах

**61:** длина строки fasta ( в input) в байтах (\*перенос строки в Linux это 1 байт, поэтому разница 1 между длиной в нуклеотидах и байтах это символ переноса строки)

## 2. Чтения ДНК

### **1) Описание образца чтений ДНК**

**SRR ID образца ДНК-чтений:** SRR10720413

\*Ссылка на информацию об образце в NCBI SRA:

<https://www.ncbi.nlm.nih.gov/sra/?term=SRR10720413>

**Прибор для секвенирования:** Illumina Genome Analyzer IIx

**Организм:** Homo sapiens

**Стратегия секвенирования:** whole-exome and RNA sequencing (экзомное)

**Какие чтения:** парноконцевые

**Сколько чтений ожидается (spots):** 38,132,996

### **2) Проверка качества исходных чтений**

У меня есть 2 файла (так как парноконцевые чтения) - SRR10720413\_1.fastq.gz (прямые) и SRR10720413\_2.fastq.gz (обратные).


```
fastqc SRR10720421_1.fastq.gz SRR10720421_2.fastq.gz
```

Получилось 2 html-файла, для прямых чтений (\_1) и для обратных (\_2).


**Количество пар чтений:** 38,132,996

**Совпадает ли количество чтений у прямых и обратных:** да, совпадает также с ожидаемым количеством

**а) Анализ качества пар чтений:**



*a) прямые чтения*



*b) обратные чтения*

**Рис. 1. Per base sequence quality**

Видим графики вида "box plot" (ящик с усами), отображающие распределение показателей качества (Quality scores) по каждой позиции в прочтении (read).

- Желтый прямоугольник («ящик»): представляет собой межквартильный размах (IQR). Он содержит 50% всех данных (от 25-го до 75-го процентиля).
  - Горизонтальная линия внутри ящика — это медиана (50-й процентиль).
- Вертикальные линии («усы»): показывают диапазон данных, не считая выбросов.
  - Верхний «ус» — это максимальное значение в пределах  $1.5 * IQR$  от верхнего квартиля.
  - Нижний «ус» — минимальное значение в пределах  $1.5 * IQR$  от нижнего квартиля.
  - Синяя линия, проходящая через центр ящиков: это среднее значение (mean) качества по каждой позиции. Она помогает визуально отследить общую тенденцию изменения среднего качества.

Цветовые полосы на фоне графика — это качественные шкалы, соответствующие стандартной кодировке Illumina:

- Красная зона (ниже ~20): очень низкое качество. Такие базы считаются ненадежными и часто отбрасываются при обработке.
- Желтая зона (~20–30): среднее качество. Базы в этой зоне могут быть использованы, но требуют осторожности.
- Зеленая зона (выше ~30): высокое качество. Это надежные базы, которые обычно используются в анализе без фильтрации.

### **Общая картина:**

Оба графика демонстрируют типичную для Illumina-данных динамику снижения качества к концу прочтения. Однако между ними есть небольшие, но важные различия, особенно в последних позициях.

### **Что общего:**

- Высокое качество в начале: В обоих чтениях медиана и среднее значение на позициях 1–50 находятся в зеленой зоне ( $Q > 35$ ). Это говорит о хорошем стартовом качестве.
- Снижение к концу: В обоих случаях наблюдается постепенное снижение среднего и медианного качества после 50 bp.
- Отсутствие резких аномалий: Нет внезапных падений или выбросов, что указывает на стабильность секвенирования.

### **Ключевые различия:**

1. Качество в конце прочтения (позиции 65–75)
  - а) прямое чтение (первый график):

- Медиана (горизонтальная линия в ящике) падает ниже 35 уже к позиции 60.

- К позиции 75 нижний "ус" опускается до ~26–27, что находится в желтой зоне (низкое/среднее качество).

- Синяя линия (среднее) также заметно снижается — к концу она близка к 34.

**b) обратное (второй график):**

- Медиана остается выше 35 почти до позиции 70.

- К позиции 75 нижний "ус" не опускается ниже 30, что еще в пределах зеленой зоны.

- Среднее значение (синяя линия) снижается медленнее — к концу оно около 36–37.

**Вывод:** обратное чтение сохраняет более высокое качество в конце прочтения, чем 1. Это частая ситуация при парном секвенировании — обратное чтение часто имеет лучшее качество на концах, поскольку оно начинается с "чистого" участка матрицы

## 2. Разброс данных


В первом разброс (высота ящика и длина усов) несколько больше, особенно в последней трети прочтения — это означает, что больше разброса.

Во втором распределение более компактное — данные более однородны.

**Вывод:** обратное чтение более стабильно по качеству, особенно в конце.

**b) Анализ длины чтений:**

вставила только 1 картинку, потому что они одинаковые для обоих типов чтений.



**Рис. 2. Sequence length distribution**

Этот график – это линейный график распределения частот (frequency distribution) длин прочтений.

Длина прочтений почти идеально однородна

График имеет острый пик на 75 bp и очень маленькое количество прочтений на 74 и 76 bp. Это говорит о том, что:

Практически все прочтения имеют длину ровно 75 bp.

Такая картина характерна для стандартных протоколов Illumina, где прочтения фиксированной длины (например, 75 bp) секвенируются без обрезки до анализа.

Небольшое количество коротких и длинных прочтений:

На 74 bp и 76 bp есть очень небольшой "хвост" – по нескольку миллионов прочтений.

Это может быть вызвано:

- Техническими проблемами (например, сбой в секвенаторе, ошибки при записи данных).
- Обрезкой адаптеров или качеством – если в начале или конце прочтения были низкокачественные базы, они могли быть удалены, что привело к укорочению некоторых прочтений.
- Ошибками в библиотеке – например, если часть молекул была слегка короче или длиннее из-за вариаций в подготовке.

Однако, поскольку эти значения малы по сравнению с пиком на 75 bp, их можно считать незначительными выбросами.

Из графика видно:


- Пик на 75 bp достигает ~35 миллионов прочтений — это абсолютное большинство.
- На 74 bp — около 5–10 миллионов.
- На 76 bp — еще меньше, примерно 5 миллионов.

Примерное соотношение:


- 75 bp: ~85–90% всех прочтений
- 74 bp и 76 bp: ~10–15% в сумме

### c) Пару слов про остальные графики:

- 1) Если продолжить тему качества чтений, то можно взглянуть на распределение чтений по среднему качеству.



- a) прямые чтения



b) обратные чтения


**Рис. 3. Per sequence quality scores**

Подавляющее большинство прочтений имеют высокое-среднее качество


- Красная линия резко поднимается только в конце, начиная с ~Q36.
- Пик гистограммы (самый высокий серый столбец) находится на уровне Q38–Q40.
- Это означает, что почти все прочтения имеют среднее качество выше 35, а большинство — выше 38.

Предыдущий график (Рис.1) показывал качество по каждой позиции внутри прочтения — там мы видели снижение к концу. Этот график показывает среднее качество по всему прочтению — то есть каждое прочтение получает одну оценку (усреднённую по всем его базам).

2) По следующему графику можно судить о процентном количестве видов нуклеотидов в данной позиции. Считается, что, если в какой-то позиции разница  $|A-T|$  или  $|G-C|$  больше 10%, то это плохо (в процессе секвенирования что-то пошло не так, и получившиеся чтения лучше переделать).



a) прямые чтения




б) обратные чтения


**Рис. 4. Per base sequence content**

На моем графике А и Т практически везде совпадают — их линии почти наложены друг на друга, есть незначительные расхождения вначале. Г и С также очень близки друг к другу — обе линии на уровне ~22–24.

3) Процент знака N (неопределенный нуклеотид) в позиции. Насторожить должно значение выше 5%, на моих графиках все 0%, то есть очень хорошо



*a) прямые чтения*



*б) обратные чтения*

**Рис. 5. Per base N content.**

Для оценки использовала мануал fastqc  
(<https://www.bioinformatics.babraham.ac.uk/projects/fastqc/>)  
Общая оценка качества чтений: замечательно

### 3) Фильтрация чтений с помощью trimmomatic

```
TrimmomaticPE -phred33 SRR10720413_1.fastq.gz
SRR10720413_2.fastq.gz trim_1_paired.fastq.gz
trim_1_unpaired.fastq.gz trim_2_paired.fastq.gz
trim_2_unpaired.fastq.gz TRAILING:20 MINLEN:50
```

**Command:** TrimmomaticPE - запускаем trimmomatic для парноконцевых чтений (поэтому PE, SE - для одноконцевых)

**Options:** -phred33 - данный Quality Score

TRAILING:20 - удаляем с конца чтений нуклеотиды с качеством ниже 20

MINLEN:50 - удаляем чтения с длиной меньше 50

**Input:** SRR10720413\_1.fastq.gz, SRR10720413\_2.fastq.gz - входные файлы с чтениями

**Output:** trim\_1\_paired.fastq.gz trim\_1\_unpaired.fastq.gz

trim\_2\_paired.fastq.gz trim\_2\_unpaired.fastq.gz - выходные файлы, \_paired - парные, \_unpaired - непарные

### 4) Анализ триммированных чтений fastqc

```
fastqc trim*
```

**Количество пар чтений осталось:** 36,950,563


**Процент пар чтений осталось:** 96.9%

#### a) Сравнение качества чтений после триммирования (paired vs unpaired):

Качество непарных чтений заметно хуже, чем качество парных


После триммирования количество непарных чтений оказалось небольшим, и их среднее качество (Q20–Q25) было заметно ниже, чем у сохранённых парных чтений (Q30+). Это ожидаемо: непарные чтения представляют собой остатки тех пар, где один из ридов не прошёл фильтрацию по длине или качеству. Их более низкое качество отражает селективный характер предобработки данных и подтверждает эффективность триммирования.

## парные чтения



прямые

обратные




непарные

Рис. 6. Per base sequence quality после триммирования

b) Сравнение качества чтений до и после триммирования (только paired):

после триммирования качество чтений улучшилось


парные чтения



до триммирования

после триммирования

## Обратные чтения




до триммирования

после триммирования


**Рис. 7. Сравнение Per base sequence quality до и после триммирования**

### с) Изменение длины чтений после триммирования:

Большая часть так и осталась 75 нуклеотидов, но: в парных чтениях появилось небольшое количество длиной меньше (74, еще меньше длиной 70); а вот у непарных длина совсем изменилась, так как появились заметной величины пики на графиках



непарные



## Часть 2:

### **1. Картирование чтений на референсный геном**

```
hisat2 -x ../chromosome/chr7 -1
..../trimm/trim_1_paired.fastq.gz -2
..../trimm/trim_2_paired.fastq.gz -p 10 --no-spliced-alignment >
map.sam 2> map_log.txt
```

**Command:** hisat2 – картирование чтений

**Options:** -x ..../chromosome/chr7 – префикс имен файлов с индексацией референса (которые были получены после индексации референса в hisat2-build, их было 8)

-1 trim\_1\_paired.fastq.gz – файл с прямыми парными триммированными чтениями

-2 trim\_2\_paired.fastq.gz – файла с обратными парными триммированными чтениями

-p 10 – использую 10 ядер процессора, чтобы быстро посчиталось

--no-spliced-alignment – параметр, запрещающий возможность сплайсинга (то есть запрещает картирование с разрывами)

**Input:** ..../chromosome/chr7 – файлы с индексацией референса

..../trimm/trim\_1\_paired.fastq.gz, ..../trimm/trim\_2\_paired.fastq.gz – парные  
тrimмированные чтения

**Output:** > map.sam – записываю вывод программы в файл .sam 2>  
map\_log.txt – сохраняю логи в txt-файл

## **2. Конвертация sam в bam**

### **1) Описание sam/bam файла**

a) Вес sam файла – 15.34 ГБ

Конвертируем этот тяжеленный файл в его бинарный аналог – map.bam

```
samtools sort -o map.bam map.sam
```

**Command:** samtools sort – сортирует файл .sam, данный в input

**Options:** -o map.bam – вывод программы в файл map.bam

**Input:** map.sam – sam файл, полученный при картировании чтений

**Output:** map.bam – bam файл

b) Вес bam файла – 4.22 ГБ

Индексация bam файла с помощью samtools index:

```
samtools index map.bam
```

**Command:** samtools index – программа, которая индексирует файл

**Input:** map.bam – исходный файл

**Output:** map.bam.bai – выходной файл

Немного про файл sam:

**Шапка:**

@SQ SN – имя референса (7), LN – длина референса (159345973)

Еще в шапке можно найти информация о программе, которая  
сгенерировала этот sam файл (ID, имя и версия программы, копия полной  
команды для выравнивания)

Рис. 1. Файл .sam

## Содержание по столбцам:

## QNAME – имя чтения

**FLAG** – информация о чтении (говорит нам как картировано чтение, каждой характеристике есть свой набор цифр. Нужна, когда мы переходим к файлу bam и фильтруем чтения)

**RNAME** – имя референсного контига (в моем случае chr7, так как она везде одинаковая, то стоит \*)

**POS** – Позиция первого нуклеотида, куда выровнялось чтение на референс

**MAPQ** – Качество картирования ( $Q = -10\lg P$ )

**CIGAR** – сколько мэтчей, количество делеций и вставок в референсе (в формате CIGAR: xMyDzI)

**RNEXT** – Название последовательности для парного (в случае РЕ) или следующего (в случае SE) чтения

**PNEXT** – POS для первого выравнивания парного (в случае PE) или

следующего (в случае SE) чтения

**TLEN** – длина участка референса, к которому прикрепилось чтение (может не совпадать с длиной чтения, так как есть делеции и вставки в референсе относительно чтения)

**SEQ** – последовательность чтения (как в fastq)

**QUAL** – качество чтения для каждой позиции нуклеотида (как в fastq)  
Дополнительная информация (опционально; здесь находится tag: видов тэгов много, каждому соответствует какое-то значение, например MQ – качество картирования парного/следующего чтения, AS – вес выравнивания, подсчитанный программой выравнивания и тд)

### 3. Анализ bam файла

Так как файл бинарный, просто посмотреть его (с помощью less, например) не получится. Поэтому запускаю программу для анализа этого файла:

```
samtools flagstat map.bam > analysed_bam.txt
```

**Command:** samtools flagstat – программа

**Input:** map.bam – исходный файл

**Output:** analysed\_bam.txt – выходной файл

```
75096733 + 0 in total (QC-passed reads + QC-failed reads)
73901126 + 0 primary
1195607 + 0 secondary
0 + 0 supplementary
0 + 0 duplicates
0 + 0 primary duplicates
5890778 + 0 mapped (7.84% : N/A)
4695171 + 0 primary mapped (6.35% : N/A)
73901126 + 0 paired in sequencing
36950563 + 0 read1
36950563 + 0 read2
4144524 + 0 properly paired (5.61% : N/A)
4226304 + 0 with itself and mate mapped
468867 + 0 singletons (0.63% : N/A)
0 + 0 with mate mapped to a different chr
0 + 0 with mate mapped to a different chr (mapQ<=5)
```

Все чтения прошли Quality Control (строка 1)

- a) Сколько чтений картировано на референс? 5890778 штуки
- b) Сколько чтений картировано на референс в % от количества триммированных? 7.84%
- c) Сколько чтений картировано на референс в корректных парах? 4144524

d) Сколько чтений картировано на референс в корректных парах в % от количества триммированных? 5.61%

Так как у нас изначально чтения всего экзома, а референс у меня только 7ая хромосома, то очевидно, что не все чтения на нее картируются. Не все парные чтения корректно картировались, например, потому что парные чтения могли картироваться не по направлению друг к другу; чтение могло картироваться на референс несколько раз (и получится, что расстояние между парными чтениями будет большим); а может быть одно из чтений вообще не картировалось

#### **4. Получение чтений, картированных на chr7**

```
samtools view -h -bS map.bam 7 > 7.chr.bam
```

**Command:** samtools view – печатает все чтения из input картированные на референс

**Options:** -h – выводить в файл вместе с заголовком

-b – вывод в файл формата bam

-S – формат файла в input определить автоматически

**Input:** map.bam – исходный файл

7 – имя моей хромосомы

**Output:** 7.chr.bam – файл bam с чтениями, картированными на 7 хромосому

```
samtools flagstat 7.chr.bam > 7chranalysed.bam.txt
```

```
6359645 + 0 in total (QC-passed reads + QC-failed reads)
5164038 + 0 primary
1195607 + 0 secondary
0 + 0 supplementary
0 + 0 duplicates
0 + 0 primary duplicates
5890778 + 0 mapped (92.63% : N/A)
4695171 + 0 primary mapped (90.92% : N/A)
5164038 + 0 paired in sequencing
2582019 + 0 read1
2582019 + 0 read2
4144524 + 0 properly paired (80.26% : N/A)
4226304 + 0 with itself and mate mapped
```

```
468867 + 0 singletons (9.08% : N/A)
0 + 0 with mate mapped to a different chr
0 + 0 with mate mapped to a different chr (mapQ>=5)
```

Рассмотрим ключевые изменения от аналогичного файла из п3:

Показатель	Весь BAM (все хромосомы)	BAM (только chr7)	Комментарий
Всего чтений	75 096 733	6 359 645	После фильтрации оставлены только чтения, относящиеся к chr7
Primary reads	73 901 126	5 164 038	Уменьшение связано с удалением чтений других хромосом
Secondary reads	1 195 607	1 195 607	Все secondary-выравнивания приходятся на chr7
Supplementary reads	0	0	Supplementary-выравнивания отсутствуют
Duplicates	0	0	Дедупликация не проводилась
<b>Mapped reads</b>	<b>5 890 778 (7.84%)</b>	<b>5 890 778 (92.63%)</b>	Абсолютное число одинаково; процент вырос из-за уменьшения общего числа чтений
<b>Primary mapped reads</b>	<b>4 695 171 (6.35%)</b>	<b>4 695 171 (90.92%)</b>	Почти все primary-выравнивания локализованы на chr7
Paired reads	73 901 126	5 164 038	Фильтрация по хромосоме
Properly paired reads	4 144 524 (5.61%)	4 144 524 (80.26%)	Высокая доля корректных пар после фильтрации
Read 1	36 950 563	2 582 019	Уменьшение пропорционально общему числу чтений

Read 2	36 950 563	2 582 019	Аналогично Read 1
Reads with mate mapped	4 226 304	4 226 304	Все такие пары соответствуют chr7
Singlettons	468 867 (0.63%)	468 867 (9.08%)	Рост процента обусловлен уменьшением знаменателя
Mate mapped to different chr	0	0	Химерные пары не обнаружены

**Таблица 1. Сравнение статистик выравнивания ВАМ-файла до и после фильтрации по хромосоме 7**

**Примечание.** Фильтрация ВАМ-файла по chr7 не изменила абсолютное число выровненных чтений, но существенно увеличила относительные показатели выравнивания. Это указывает на то, что практически все выровненные чтения исходного ВАМ-файла локализованы на хромосоме 7.

## 5. Получение только правильно картированных пар чтений

```
 samtools view -f 2 -bs 7.chr.bam > correct_7.bam
```

**Options:** -f 2 – оставить только те чтения, у которых в флаге выравнивания установлен бит 0x2 (то есть чтения, помеченные как properly paired)

```
5066138 + 0 in total (QC-passed reads + QC-failed reads)
4144524 + 0 primary
921614 + 0 secondary
0 + 0 supplementary
0 + 0 duplicates
0 + 0 primary duplicates
5066138 + 0 mapped (100.00% : N/A)
4144524 + 0 primary mapped (100.00% : N/A)
4144524 + 0 paired in sequencing
2072262 + 0 read1
2072262 + 0 read2
4144524 + 0 properly paired (100.00% : N/A)
4144524 + 0 with itself and mate mapped
0 + 0 singlettons (0.00% : N/A)
0 + 0 with mate mapped to a different chr
0 + 0 with mate mapped to a different chr (mapQ>=5)
```

Ключевые отличия от выдачи из пункта 4:

Показатель	BAM chr7 (все чтения)	BAM chr7 (только properly paired)	Комментарий
Всего чтений	6 359 645	5 066 138	Удалены одиночные, неправильно спаренные и не полностью выровненные чтения
Primary reads	5 164 038	4 144 524	Остались только primary properly paired чтения
Secondary reads	1 195 607	921 614	Secondary-выравнивания сохранены только для корректных пар
Supplementar y reads	0	0	Supplementary-выравнивания отсутствуют
Duplicates	0	0	Дедупликация не проводилась
<b>Mapped reads</b>	<b>5 890 778 (92.63%)</b>	<b>5 066 138 (100.00%)</b>	После фильтрации все чтения выровнены
<b>Primary mapped reads</b>	<b>4 695 171 (90.92%)</b>	<b>4 144 524 (100.00%)</b>	Исключены primary чтения без корректной пары
Paired reads	5 164 038	4 144 524	Удалены некорректно спаренные пары
<b>Properly paired reads</b>	<b>4 144 524 (80.26%)</b>	<b>4 144 524 (100.00%)</b>	Отбор по SAM-флагу 0x2
Read 1	2 582 019	2 072 262	Пропорциональное уменьшение
Read 2	2 582 019	2 072 262	Пропорциональное уменьшение
Reads with mate mapped	4 226 304	4 144 524	Исключены некорректные пары
Singletons	468 867 (9.08%)	0 (0.00%)	Полностью исключены

Mate mapped to different chr	0	Межхромосомные пары отсутствуют
------------------------------	---	---------------------------------

**Таблица 2. Статистики ВАМ-файла chr7 до и после отбора только корректно выровненных пар чтений**

**Примечание.** Фильтрация с использованием параметра `samtools view -f 2` приводит к формированию ВАМ-файла, содержащего исключительно корректно выровненные парные чтения на хромосоме 7. Это подтверждается 100% долей mapped и properly paired reads.

Теперь проиндексирую файл:

```
samtools index correct_7.bam
```

## **6. Получение чтений, картированных только в границы экзона**

```
bedtools intersect -a correct_7.bam -b
/mnt/scratch/NGS/DATA/genes/seqcap_hg38.bed > exom_7_chr.bam

3328307 + 0 in total (QC-passed reads + QC-failed reads)
2699700 + 0 primary
628607 + 0 secondary
0 + 0 supplementary
0 + 0 duplicates
0 + 0 primary duplicates
3328307 + 0 mapped (100.00% : N/A)
2699700 + 0 primary mapped (100.00% : N/A)
2699700 + 0 paired in sequencing
1348451 + 0 read1
1351249 + 0 read2
2699700 + 0 properly paired (100.00% : N/A)
2699700 + 0 with itself and mate mapped
0 + 0 singletons (0.00% : N/A)
0 + 0 with mate mapped to a different chr
0 + 0 with mate mapped to a different chr (mapQ>=5)
```

Для выделения чтений, попадающих в экзомные регионы, был использован BED-файл с координатами экзома (seqcap\_hg38.bed). Фильтрация выполнена с помощью bedtools intersect, применённого к BAM-файлу, содержащему только корректно выровненные парные чтения хромосомы 7 (correct\_7.bam).

После пересечения с экзомными координатами общее число чтений составило 3 328 307, из которых 2 699 700 являются primary-выравниваниями. Все чтения в итоговом файле полностью выровнены на референсный геном, что подтверждается 100% долей mapped и properly paired reads. Одиночные чтения (singletons), некорректно спаренные пары, а также межхромосомные выравнивания отсутствуют.

Сохранение 628 607 secondary-выравниваний указывает на наличие альтернативных выравниваний для части чтений, что является ожидаемым для экзомных ‘частей’ с повторяющимися или гомологичными последовательностями. Дубликаты и supplementary-выравнивания не обнаружены.

Таким образом, итоговый BAM-файл содержит исключительно корректно выровненные парные чтения, локализованные в пределах экзомов хромосомы 7.

## **7. Получение чтений, картированных в границы расширенного экзома**

```
bedtools intersect -a correct_7.bam -b
/mnt/scratch/NGS/DATA/genes/seqcap_hg38_50.bed >
exom_extended_7_chr.bam

3643449 + 0 in total (QC-passed reads + QC-failed reads)
2951919 + 0 primary
691530 + 0 secondary
0 + 0 supplementary
0 + 0 duplicates
0 + 0 primary duplicates
3643449 + 0 mapped (100.00% : N/A)
2951919 + 0 primary mapped (100.00% : N/A)

2951919 + 0 paired in sequencing
1475325 + 0 read1
1476594 + 0 read2
2951919 + 0 properly paired (100.00% : N/A)
```

```

2951919 + 0 with itself and mate mapped
0 + 0 singlettons (0.00% : N/A)
0 + 0 with mate mapped to a different chr
0 + 0 with mate mapped to a different chr (mapQ>=5)

```

Показатель	Экзом (seqcap_hg38.b ed)	Расширенный экзом (seqcap_hg38_50.b ed)	Комментарий
Всего чтений	3 328 307	3 643 449	Увеличение числа чтений за счёт расширения экзомных границ
Primary reads	2 699 700	2 951 919	В расширенный экзом попали дополнительные primary-выравнивания
Secondary reads	628 607	691 530	Рост числа альтернативных выравниваний
Supplementary reads	0	0	Отсутствуют в обоих наборах
Duplicates	0	0	Дедупликация не проводилась
<b>Mapped reads</b>	<b>3 328 307 (100.00%)</b>	<b>3 643 449 (100.00%)</b>	Все отобранные чтения полностью выровнены
<b>Primary mapped reads</b>	<b>2 699 700 (100.00%)</b>	<b>2 951 919 (100.00%)</b>	100% primary выравниваний в обоих случаях
Paired reads	2 699 700	2 951 919	Все чтения являются корректно спаренными

Read 1	1 348 451	1 475 325	Пропорциональное увеличение
Read 2	1 351 249	1 476 594	Пропорциональное увеличение
<b>Properly paired reads</b>	<b>2 699 700 (100.00%)</b>	<b>2 951 919 (100.00%)</b>	Корректные пары сохранены полностью
Reads with mate mapped	2 699 700	2 951 919	Оба чтения пары выровнены
Singletons	0 (0.00%)	0 (0.00%)	Одиночные чтения отсутствуют
Mate mapped to different chr	0	0	Межхромосомные выравнивания отсутствуют

**Таблица 3. Сравнение статистик чтений chr7, картированных в  
границы экзома и расширенного экзома**

**Примечание.** Расширенный экзом (seqcap\_hg38\_50.bed) включает экзонные регионы с дополнительными фланкирующими участками ( $\pm 50$  п.н.), что приводит к увеличению числа отобранных чтений по сравнению со стандартным экзомом (seqcap\_hg38.bed). При этом качество выравнивания остаётся неизменным: все чтения корректно спарены и полностью выровнены на референсный геном.

# Практикум 12

## 1. Получение вариантов

Варианты на хромосоме 7 были вызваны с использованием bcftools mpileup и bcftools call. Использован BAM-файл с корректно выровненными парными чтениями (correct\_7.bam) и референс chr7.fa. Все позиции считались диплоидными, максимальная глубина на позицию ограничена 250 чтениями, вызваны только SNP и Indel

\*Note: none of --samples-file, --ploidy or --ploidy-file given, assuming all sites are diploid

[mpileup] 1 samples in 1 input files

[mpileup] maximum number of reads per input file set to -d 250

```
bcftools mpileup -f ../chromosome/chr7.fa
..../mapping/correct_7.bam | bcftools call -mv -o variants.vcf
```

**Command:** bcftools mpileup – генерирует vcf файл, в котором находятся вероятности разных вариантов (на основании выравнивания)

**Options:** -f ../chromosome/chr7.fa – указывают референс

**Input:** ../chromosome/chr7.fa – референс

..../mapping/correct\_7.bam – файл bam с картированными ридами

**Command:** bcftools call – из output (stdout) программы bcftools mpileup берет только нужные строки (характеристики указаны в options)

**Options:** -m – модель, которая ищет мультиаллельные и редкие варианты  
-v – на выдачу попадут только варианты

-o variants.vcf – выдача в файл variants.vcf

**Input:** output из bcftools mpileup

**Output:** variants.vcf

Теперь нужно посмотреть на сам vcf файл

```
##fileformat=VCFv4.2
##FILTER=<ID=PASS,Description="All filters passed">
##bcftoolsVersion=1.16+htslib-1.16
##bcftoolsCommand=multiplex -f ../chromosome/chr7.fa ../mapping/correct_7.bam
##referenceFile:///chromosome/chr7.fa
##contig=<ID=7,length=15934597>
##ALT=<ID=*,Description="Represents allele(s) other than observed.">
##INFO=<ID=INDEL,Number=0,Type=Flag,Description="Indicates that the variant is an INDEL.">
##INFO=<ID=IDV,Number=1,Type=Integer,Description="Maximum number of raw reads supporting an indel">
##INFO=<ID=IMF,Number=1,Type=Float,Description="Maximum fraction of raw reads supporting an indel">
##INFO=<ID=IDN,Number=1,Type=Integer,Description="Raw read depth">
##INFO=<ID=VDB,Number=1,Type=Float,Description="Variant Distance Bias for filtering splice-site artefacts in RNA-seq data (bigger is better)",Version="3">
##INFO=<ID=RPBZ,Number=1,Type=Float,Description="Mann-Whitney U-z test of Read Position Bias (closer to 0 is better)">
##INFO=<ID=MQ0,Number=1,Type=Float,Description="Mann-Whitney U-z test of Mapping Quality Bias (closer to 0 is better)">
##INFO=<ID=RBQ,Number=1,Type=Float,Description="Mann-Whitney U-z test of Base Quality Bias (closer to 0 is better)">
##INFO=<ID=MQSBZ,Number=1,Type=Float,Description="Mann-Whitney U-z test of Mapping Quality vs Strand Bias (closer to 0 is better)">
##INFO=<ID=MQEZ,Number=1,Type=Float,Description="Mann-Whitney U-z test of Number of Mismatches within supporting reads (closer to 0 is better)">
##INFO=<ID=SCL,Number=1,Type=Float,Description="Mann-Whitney U-z test of Soft-Clip length Bias (closer to 0 is better)">
##INFO=<ID=FS,Number=1,Type=Float,Description="Phred-scaled p-value using Fisher's exact test to detect strand bias">
##INFO=<ID=SGB,Number=1,Type=Float,Description="Segregation based metric.">
##INFO=<ID=MQ0,Number=1,Type=Float,Description="Fraction of MQ0 reads (smaller is better)">
##FORMAT=<ID=PL,Number=0,Type=Integer,Description="List of Phred-scaled genotype likelihoods">
##FORMAT=<ID=GT,Number=1,Type=String,Description="Genotype">
##INFO=<ID=AC,Number=A,Type=Integer,Description="Allele count in genotypes for each ALT allele, in the same order as listed">
##INFO=<ID=AN,Number=1,Type=Integer,Description="Total number of alleles in called genotypes">
##INFO=<ID=DP4,Number=4,Type=Integer,Description="Number of high-quality ref-forward, ref-reverse, alt-forward and alt-reverse bases">
##INFO=<ID=MQ,Number=1,Type=Integer,Description="Average mapping quality">
##bcftools_callVersion=1.16+htslib-1.16
##bcftools_callCommand=<ID=mv -o variants.vcf; Date=fri Dec 19 13:15:05 2025
#CHROM POS ID REF ALT QUAL FILTER INFO FORMAT .../mapping/correct_7.bam
7 10479 . C T 133,416 . DP=5;VDB=0.0815962;SGB=0.590765;MQSBZ=0;FS=0;MQF=0;AC=2;AN=2;DP4=0,0,3,2;MQ=60 GT:PL 1/1:163,15,0
7 10526 . G T 46,2234 . DP=3;VDB=0.692431;SGB=0.556411;MQSBZ=0;FS=0;MQF=0;AC=1;AN=2;DP4=3,1,4,0;MQ=60 GT:PL 0/1:79,0
,138 ,28 10739 . A G 63,2738 . DP=4;VDB=0.154358;SGB=0.511536;RPBZ=-0.447214;MQSBZ=0;BQ8Z=-0.942809;NMBZ=0.57735;SCBZ=0;FS=0;MQF=0;AC=1;AN=2;DP4=1,0,2,1;MQ=60 GT:PL 0/1:97,0
7 10846 . C T 41,4148 . DP=2;VDB=0.76;SGB=0.453602;FS=0;MQF=0;AC=2;AN=2;DP4=0,0,0,2;MQ=60 GT:PL 1/1:71,6,0
7 11153 . A G 80,4149 . DP=3;VDB=0.833545;SGB=0.611536;MQSBZ=0;FS=0;MQF=0;AC=2;AN=2;DP4=0,0,1,2;MQ=60 GT:PL 1/1:110,9,0
7 11229 . A G 8,92702 . DP=2;SGB=0.379885;RPBZ=-1;MQBZ=0;NMBZ=1;SCBZ=0;FS=0;MQF=0;AC=2;AN=2;DP4=0,1,0,1;MQ=30 GT:PL 1/1:35,1,0
7 11298 . A G 3,20206 . DP=2;SGB=0.379885;RPBZ=-1;MQBZ=0;NMBZ=0;BQ8Z=0;SCBZ=0;FS=0;MQF=0;AC=1;AN=2;DP4=0,1,1,0;MQ=60 GT:PL 0/1:33,0,33
7 11554 . G A 8,92702 . DP=2;SGB=0.379885;RPBZ=-1;MQBZ=1;BQ8Z=0;SCBZ=1;FS=0;MQF=0;AC=2;AN=2;DP4=0,1,0,1;MQ=30 GT:PL 1/1:35,1,0
7 11619 . G A 5,04598 . DP=1;SGB=0.379885;FS=0;MQF=0;AC=2;AN=2;DP4=0,0,0,1;MQ=60 GT:PL 1/1:33,5,0
7 12084 . T C 3,77188 . DP=2;SGB=0.379885;RPBZ=-1;MQBZ=0;BQ8Z=1;NMBZ=1;SCBZ=1;FS=0;MQF=0;AC=1;AN=2;DP4=0,1,1,0;MQ=60 GT:PL 0/1:34,0,33
7 12302 . A G 75,4149 . DP=4;VDB=0.468446;SGB=0.511536;MQSBZ=0;FS=0;MQF=0;AC=2;AN=2;DP4=0,0,0,2,1;MQ=60 GT:PL 1/1:105,9,0
7 12362 . T G 49,4149 . DP=2;VDB=0.453602;SGB=0.453602;FS=0;MQF=0;AC=2;AN=2;DP4=0,0,1,1;MQ=60 GT:PL 1/1:79,6,0
7 12783 . C T 101,415 . DP=4;VDB=0.0846255;SGB=0.556411;MQSBZ=0;FS=0;MQF=0;AC=2;AN=2;DP4=0,0,3,1;MQ=60 GT:PL 1/1:131,12,0
7 13062 . A G 3,77188 . DP=2;SGB=0.379885;RPBZ=1;MQBZ=0;BQ8Z=1;SCBZ=0;FS=0;MQF=0;AC=2;AN=2;DP4=0,1,0,1;MQ=60 GT:PL 0/1:34,0,33
7 13229 . G A 23,251 . DP=5;VDB=0,32;SGB=0.453602;RPBZ=0.756787;NMBZ=0.408248;SCBZ=0;FS=0;MQF=0;AC=1;AN=2;DP4=1,2,0;MQ=60 GT:PL 0/1:56,0,94
7 13384 . A G 39,1346 . DP=4;VDB=0.0264014;SGB=0.511536;RPBZ=0;NMBZ=0;SCBZ=0;FS=0;MQF=0;AC=1;AN=2;DP4=1,3,0,3;MQ=60 GT:PL 0/1:72,0
,137 ,0,17 13394 . C T 82,2206 . DP=7;VDB=0.592253;SGB=0.616816;RPBZ=1;SGB=0.511536;MQSBZ=0;BQ8Z=0.756787;NMBZ=0.408248;SCBZ=0;FS=0;MQF=0;AC=1;AN=2;DP4=1,0,0,6;MQ=60 GT:PL 0/1:117,
7 13658 . AAG AAGGAG 121,415 . INDEL;IDV=3;IMF=1;DP=3;VDB=0.235765;SGB=0.511536;MQSBZ=0;BQ8Z=0.756787;FS=0;MQF=0;AC=2;AN=2;DP4=0,0,3;MQ=60 GT:PL 1/1:151,9,0
```

Рис. 1. Файл .vcf

### Что можно сказать про файл .vcf?

Сначала идет шапка файла, каждая строка начинается с `##`. Затем перед «телом файла» идет строка с заголовками столбцов, она начинается с `#`.

А теперь поподробнее о каждом столбце: [что можно найти?](#)

**CHROM** – имя хромосомы

**POS** – позиция варианта

**FILTER** – везде стоят «.», но может быть любая информация о варианте

**ALT** – альтернативный аллель (так как у нас SNP, то здесь стоит одна буква)

**QUAL** – качество варианта

**FILTER** – везде «.», так как ввели файл, который уже был маркирован по качеству

**INFO** – характеристики варианта

**FORMAT** – список параметров варианта (для конкретного образца)

А теперь проанализируем variants.vcf

```
bcftools stats variants.vcf > var_stats.txt
```

```

# SN      [2]id      [3]key      [4]value
SN      0          number of samples:      1
SN      0          number of records:    74220
SN      0          number of no-ALTs:     0
SN      0          number of SNPs:      73033
SN      0          number of MNPs:      0
SN      0          number of indels:    1187
SN      0          number of others:    0
SN      0          number of multiallelic sites: 77
SN      0          number of multiallelic SNP sites: 44

```

- a) Сколько получилось вариантов? 74220
- b) Сколько из них являются SNP? 73033
- c) Сколько получилось коротких вставок и делеций? 1187 (индели)
- d) Смотрим на выход первой части команды (bcftools mpileup)

```

bcftools mpileup -f ../chromosome/chr7.fa
..../mapping/correct_7.bam > whole_variants.vcf

```

Программа выдаст информацию по всем позициям последовательности хромосомы. Тут для большинства позиций в поле ALT стоит <\*>, так как нет альтернативных позиций.

## 2. Фильтрация вариантов

```
bcftools filter -i'QUAL>30 && DP>50' variants.vcf \ -o filtred_variants.vcf
```

Command: bcftools filter – программа, которая отфильтрует варианты из input файла по заданным параметрам

Options: -i'QUAL>30 && DP>50' – фильтруем по параметрам: качество больше 30 и длина больше 50

-o filt\_variants.vcf – вывод программы в указанный файл

Input: variants.vcf

Output: filt\_variants.vcf

анализируем полученный файл

```
bcftools stats filtred_variants.vcf > filt_var_stats.txt
```

```

# SN      [2]id      [3]key      [4]value
SN      0          number of samples:      1
SN      0          number of records:    2340
SN      0          number of no-ALTs:    0
SN      0          number of SNPs:      2237
SN      0          number of MNPs:      0
SN      0          number of indels:    103
SN      0          number of others:    0
SN      0          number of multiallelic sites: 8
SN      0          number of multiallelic SNP sites: 2

```

- a) Сколько осталось вариантов после фильтрации? 2340 штук, 3.15%
- b) Сколько осталось SNP? 2237 штук, 3,06%
- c) Сколько осталось коротких вставок и делеций? 103 штуки, 8,7%

### 3. Аннотация вариантов

Category	Count
Variants processed	2340
Variants filtered out	0
Novel / existing variants	431 (18.4) / 1909 (81.6)
Overlapped genes	986
Overlapped transcripts	10191
Overlapped regulatory features	34

Таблица 1

Всего в файле было 2340 вариантов

Из них отфильтровано 0, то есть все было проаннотированы

Новые варианты – 431 (сведения о них нет ни в каком формате в базах, например, в clinvar), а существующих и уже аннотированных где-то вариантов – 1909

Перекрывающихся генов – 986

Перекрывающихся транскриптов – 10191

Перекрывающихся регуляторных областей- 34

## Consequences (all)




Рис. 2. Распределение эффектов (consequences) мутаций

Дадим обзорную характеристику:

Все мутации, кроме тех, которые перечислены ниже имеют влияние на транскрипт «**MODIFIER**», то есть либо не влияют вообще, либо затрагивают некодирующие гены/области. Это и логично, ведь если бы было много мутаций, которые влияют на транскрипты,

**5%** мутаций относятся к synonymous variant, то есть синонимичным заменам, и имеют влияние «**LOW**», то есть в большинстве своем не меняют функцию/поведение белка (что и понятно по определению синонимичной мутации, хотя есть случаи, когда они влияют на структуру: например, если замена синонимичная, но при этом заменить на более редкий кодон, тогда скорость трансляции уменьшается, нарушается фолдинг (который идет во время трансляции), вследствие чего структура и функции белка могут нарушиться

**5%** мутаций относятся к missense mutations и имеют влияние «**Moderate**». Белок транслируется, но неправильно, вследствие чего меняется его структура, а дальше либо теряется функция, либо меняется

А теперь отдельно посмотрим на кодирующие области, ведь интересующую нас патогенность или изменения вызывают, в большинстве своем, именно они

## Coding consequences



Рис. 8. Распределение эффектов (consequences) мутаций кодирующих областей

Очевидно, что большинство из них будут повторять мутации кодирующих областей из предыдущего графика.

Опасно выглядит 2% stop gained, то есть преждевременный стоп-кодон. Это приводит к укороченным транскриптам, которые могут терять/частично терять функцию. Такие мутации очень могут быть патогенными. Остальные варианты встречаются 0% (но это, видимо, просто округление?) Иначе зачем вообще вносить их в диаграмму), но в целом они с уровнями влияния на транскрипт «MODERATE» и «HIGH».

Отдельно поговорим про варианты с **HIGH IMPACT**, потому что именно они вызовут вопросы, если мы будем искать патогенные мутации. Выпишу типы мутаций из выдачи, которые характеризуются HIGH влиянием.

Подавляющее большинство мутаций с HIGH IMPACT ожидается получить в экзонах (хотя, при альтернативном сплайсинге инtron одного транскрипта может быть экзоном другого... и много разного можно придумать, но логично ожидать в экзонах!). И точно все они должны попасть в ген.

После фильтрации получилось, что **138 вариантов** с IMPACT = HIGH

Дадим характеристику вариантам:

**a) Относительно генов (попали в ген или нет)**

Практически все варианты попадают в гены - В колонке Gene указан Ensembl-идентификатор (ENSG...) для всех записей. Исключение составляют две строки с Gene = ENSG00000299721 и SYMBOL = - — это lncRNA (long non-coding RNA), т.е. всё равно функциональный некодирующий ген. Имеется один вариант Gene = ENSG00000273024, SYMBOL = INTS4P2 — транс-некодирующий псевдоген.

**Вывод:** все варианты находятся внутри аннотированных генов (кодирующих или некодирующих)

**b) Относительно структуры генов (экзон/инtron)**

**Экзоны:** большинство имеет непустое поле EXON (например, 8/29, 2/2, 4/4 и т.д.).

**Интроны:** варианты со значением в колонке INTRON отсутствуют

**Спlices-сайты:** есть варианты с Consequence = splice\_donor\_variant или splice\_acceptor\_variant, которые расположены на границах экзон-инtron

**Вывод:** все варианты затрагивают экзоны либо спlices-сайты, ни один не находится внутри интрана

**c) Относительно приносимых изменений (типы мутаций)**

Тип мутации	Краткое описание	Примеры в файле
<b>stop_gained</b>	Нонсенс-мутация (ранний стоп-кодон) → 'усеченный' белок	VWDE, ARL4A, NFE2L3, KMT2C, ZNF117, DNAJB6
<b>frameshift_variant</b>	Сдвиг рамки считывания → полная потеря функции	ARL4A, NFE2L3, ZNF727, KMT2C
<b>stop_lost</b>	Потеря стоп-кодона → 'удлинённый' белок	SEPTIN14, KMT2C

<b>splice_donor_variant</b>	Нарушение донорного сайта сплайсинга	KMT2C
<b>splice_acceptor_variant</b>	Нарушение акцепторного сайта сплайсинга	KMT2C, SEPTIN14, lncRNA
<b>non_coding_transcript_variant</b>	Затрагивает некодирующий транскрипт	lncRNA, псевдогены

**Таблица 1.**

**Вывод:** все варианты с IMPACT = HIGH – это мутации, серьёзно нарушающие структуру или экспрессию гена: нокдаун (stop\_gained, frameshift), нарушение процессинга мРНК (splice\_donor/acceptor), удлинение белка (stop\_lost). Нет ни одного missense, synonymous или regulatory варианта – такие получают IMPACT = MODERATE или LOW

# Практикум 13

## 1. Описание образца

a) ID образца РНК-чтений: **ENCFF641WPY**

b) Ссылка на информацию об образце:

<https://www.encodeproject.org/report/?type=Experiment&searchTerm=ENCFF641WPY>

c) Организм и ткань: *Mus musculus* strain B6CASTF1/J heart tissue male adult (18-20 months)

d) Стратегия секвенирования: total RNA-seq

e) Тип чтений: SE (одноконцевые): SE single-ended

f) Цепь-специфичность: нет

## 2. Проверка качества исходных чтений

```
fastqc ENCFF641WPY.fastq.gz
```

1) **Количество чтений:** 48,692,928

2) **Качество чтений:**


Среднее качество (синяя линия) стабильно находится в зелёной зоне (>30) на протяжении всей длины прочтения.

Минимальное качество (нижняя граница ящика) также остаётся выше 30, что указывает на отсутствие значительного падения качества

В начале (позиции 1-5) среднее качество чуть ниже 35, но всё ещё в «хорошем» диапазоне, почему там нет ящиков я не знаю простите


На конце (позиция 97) – небольшое снижение, но мне кажется не критичное.

Чтения высокого качества, пригодны для последующего анализа без необходимости триммирования. Падение качества в конце и в начале минимально.



**Рис. 1. Per base sequence quality**


**3) Длина чтений:**



**Рис. 2. Sequence Length Distribution**


Длина чтений в этом образце РНК-секвенирования является строго фиксированной и составляет 100 пар оснований (bp). Количество чтений с длиной 99 bp и 101 bp пренебрежимо мало, а все остальные длины отсутствуют. Такая идеально узкая и высокая пиковая форма указывает на то, что секвенирование было выполнено с использованием строго контролируемой длины чтения, что типично для стандартных протоколов Illumina, где задается фиксированная длина цикла (например, 100 циклов).

#### 4) Другие графики



**Рис. 3. Per sequence quality scores**

Большинство чтений имеют средний балл качества (Phred score) выше 30. Кривая резко возрастает в правой части графика, показывая, что подавляющее большинство чтений обладают отличным качеством (в основном 35–38). Очень мало чтений имеют низкое качество (ниже 20), что свидетельствует о хорошем качестве секвенирования и отсутствии значительных технических проблем.



**Рис. 4. Per base sequence content**

В начале чтений (первые 10–15 позиций) наблюдается сильное отклонение от ожидаемого равномерного распределения нуклеотидов, что указывает на наличие артефактов – вероятно, остатков адаптеров или биологических особенностей (например, обогащение определёнными последовательностями в 5'-конце транскриптов).

Начиная примерно с 20-й позиции и до конца чтения (100 bp), содержание нуклеотидов стабилизируется и колеблется вокруг 25% для каждого из A, T, C, G – что соответствует ожидаемому поведению для случайной последовательности. Это говорит о том, что основная часть данных качественная и не содержит систематического смещения.

Такое поведение типично для RNA-seq данных, особенно при использовании стратегии total RNA-seq без отбора по поли-А хвосту: в начале могут присутствовать рибосомные РНК, некодирующие РНК или фрагменты с неравномерным составом.

### 3. Картрирование чтений на референс

```
hisat2 -x ../chromosome/chr7 -k 3 -U  
..../rna/ENCFF641WPY.fastq.gz > rna_map.sam 2> rna_map_log.txt
```

**Command:** hisat2 – картрирование чтений

**Options:** -x ..../chromosome/chr7 – префикс имен файлов с индексацией референса (которые были получены после индексации референса в hisat2-build, их было 8)

-k 3 – максимально возможное количество выравниваний (3), чей score больше или равен score любого другого выравнивания (но hisat2 не даёт гарантий, что это лучшие выравнивания)

-U ..../rna/ENCFF641WPY.fastq.gz – файл с чтениями

**Input:** ..../chromosome/chr7 – файлы с индексацией референса

..../rna/ENCFF641WPY.fastq.gz – РНК-чтения

**Output:** rna\_map.sam – записываю вывод программы в файл .sam

rna\_map\_log.txt – сохраняю логи в txt-файл

Заглянем в rna\_map\_log.txt

48692928 reads; of these:

48692928 (100.00%) were unpaired; of these:

48667000 (99.95%) aligned 0 times

23915 (0.05%) aligned exactly 1 time

2013 (0.00%) aligned >1 times

0.05% overall alignment rate

**Сколько чтений картрировалось на хромосому?**

выровнялись ровно 1 раз: 23915 чтений

выровнялись более 1 раза: 2013 чтений

Всего картрировалось (на хромосому/хромосомы):

23915 + 2 013 = **25928** чтений

Это соответствует указанным ~0,05% от 48,692,928 чтений.

Мне казалось, что будет больше (сужу по проценту), учитывая, что качество неплохое, однако у нас весь транскриптом и только 1 хромосома

**Перевод в bam файл:**

```
samtools sort -o rna_map.bam rna_map.sam
```

**Индексация bam файла:**

```
samtools index rna_map.bam
```

**Отбор только тех чтений, которые картировались на хромосому:**

```
samtools view -h -bS rna_map.bam 7 > chr7_rna_map.bam
```

#### **4. Поиск экспрессирующихся генов**

Скачала файл с геномной разметкой Homo\_sapiens.GRCh38.110.chr.gtf

Сначала идет шапка:

```
#!genome-build GRCh38.p14 - версия разметки
#!genome-version GRCh38 - версия генома, на которой строили
#!genome-date 2013-12 - дата публикации
#!genome-build-accession GCA_000001405.29- AC разметки
#!genetbuild-last-updated 2023-03 - последняя дата обновления
```

После шапки идет тело файла. В каждой строке содержится информация о разметке, разделенная на 9 столбцов:

**seqname** - название последовательности, где аннотирован ген (в нашем случае имя хромосомы)

**source** - источник аннотации (просмотрела файл, чаще всего встречается ensembl и Havana)

**feature** - особенности гена

**start** - начало гена

**end** - конец гена

**score** - какое-то значение, вместо которого во всем файле стоит «.» (в мануале A floating point value, не особо понимаю, что это конкретно значит, но вероятно что-то о достоверности/качестве)

**strand** - цепь, на которой этот ген находится

**frame** - (сдвиг) рамка считывания

**attribute** - дополнительная информация

## Сколько аннотированных генов на 7 хромосоме?

```
grep '^7' *gtf | cut -f3 | grep 'gene' | wc -l
```

Получаем ответ: **3147**

Почему-то по разным источникам их 1400-1800, а у меня получилось в 2 раза больше. Вроде по файлу нашла все логично: беру строки с 7 хромосомой, в третьем столбце (feature) считаю только те, которые описаны как 'gene'...)

Теперь посчитаем для каждого гена из разметки число картированных на этот ген чтений:

```
htseq-count -f bam -s no -t exon -m union chr7_rna_map.bam  
..../Homo_sapiens.GRCh38.110.chr.gtf -o count_exons.sam 1>  
count_log1.txt 2> count_log2.txt
```

**Command:** htseq-count – картирование чтений

**Options:** -f bam – входной файл в формате bam

-s no – у чтений не указана цепь, поэтому они могут попадать и на прямую, и на обратную цепи

-m union – если чтения перекрываются, то их нужно объединить

-t exon – особенность гена (из 3 столбца), считаются только чтения, которые картировались на гены с этой особенностью. Так как по дефолту имеет значение exon, его и поставлю

-o count\_exons.sam – выходной файл

**Input:** chr7\_rna\_map.bam – чтения, картированные на 7 хромосому

..../Homo\_sapiens.GRCh38.110.chr.gtf – генетическая разметка

**Output:** count\_exons.sam – sam файл с аннотированными выравниваниями

count\_log1.txt (из stdout) – сводка о работе программы

count\_log2.txt (из stderr) – файл с ошибками

В файле count\_log1.txt находится информация про гены:

__no_feature	2507
__ambiguous	819
__too_low_aQual	0
__not_aligned	0
__alignment_not_unique	2013

**Сколько чтений попало в границы генов с (-t exon)?**

```
awk '$2>0 && $1 !~ /^__/' count_log1.txt | awk '{s+=$2} END {print s}'
```

**20589** чтений

**Сколько чтений попало мимо границ экзонов (-t exon)?**

см. no feature - 2 507 чтений

**Объяснение всех строк аннотационного файла:**

**\_\_no\_feature** – чтения, которые попали вне экзонов

**\_\_ambiguous** – 819 чтений ассоциированы с более чем одной особенностью гена (-t, feature)

**\_\_too\_low\_aQual** – чтения, которые были бы пропущены, если бы программе дали опцию -а (пропустить чтения с весом выравнивания ниже заданного)

**\_\_not\_aligned** – чтения в файле без выравнивания (таких нет, так на вход получен файл с чтениями, про которые точно известно картирование на 7 хромосому)

**\_\_alignment\_not\_unique** – количество чтений, у которых больше одного выравнивания

## 5. Аннотация высоко экспрессируемых генов

сортируем по убыванию количества каунтов:


```
grep -v '^__' count_log1.txt | sort -k2,2nr > count_sorted_desc.txt
```

a) head count\_sorted\_desc.txt:

ENSG00000002079	3525
ENSG00000122566	2167
ENSG00000105953	2024
ENSG00000233476	1217
ENSG00000231167	843
ENSG00000122545	658
ENSG00000105835	552
ENSG00000128595	522
ENSG00000136261	415
ENSG00000168090	365

б) Для визуализации в геномном браузере выберем **один из самых** высоко экспрессируемых белок-кодирующих генов.

Из топ-10 самый явный кандидат — **ENSG00000002079**, который соответствует гену **MYH16** (myosin heavy chain 16)



**Рисунок 5. Экзон-инtronная структура известных транскриптов**

Визуализация получена с использованием UCSC Genome Browser (сборка GRCh38/hg38) на основе аннотаций GENCODE/Ensembl. Прямоугольниками показаны экзоны, линиями — интроны; каждая строка соответствует отдельному транскрипту гена.

с) **MYH16 (myosin heavy chain 16)** — ген, относящийся к семейству миозиновых тяжёлых цепей. В большинстве млекопитающих он кодирует белок миозиновой тяжёлой цепи, участвующий в сокращении мышц, особенно жевательных мышц (temporalis и masseter). Мышечные миозины — это моторные белки, которые связываются с актином и обладают активностью АТР-азы, генерируя силу и движение в мышечных волокнах. Однако в человеке MYH16 считается псевдогеном или сильно ослабленным геном, поскольку у нас есть мутация, приводящая к неработоспособному белку; это объясняет уменьшенные размеры жевательных мышц по сравнению с другими приматами. В не-человеческих приматах функциональный MYH16 обеспечивает большую жевательную силу

\*Информация из GeneCards

## СКРИПТ ДЛЯ ПРАКТИКУМОВ 11-12

**В папке:** /mnt/scratch/NGS/bratzveron/script

**Запуск:** cd /mnt/scratch/NGS/bratzveron/script

./script.sh SRR10720421 7

```
#!/bin/bash
#script.sh
#usage: ./script.sh sample_id chr_number
#пример: ./script.sh SRR10720421 7
#автоматизированный пайплайн:
#с->триммирование->картирование->фильтрация bam->вызов и
#фильтрация vcf
#референс grch38.p14, ensembl release 110

#настройки по умолчанию
reads_dir=/mnt/scratch/NGS/DATA/dna_reads
ref_dir=/mnt/scratch/NGS/DATA/hg38
genes_gtf=/mnt/scratch/NGS/DATA/genes/Homo_sapiens.GRCh38.110.
chr.gtf
bed_file=/mnt/scratch/NGS/DATA/genes/seqcap_hg38.bed
bed_extended=/mnt/scratch/NGS/DATA/genes/seqcap_hg38_50.bed

phred=phred33
trim_trailing=20
trim_minlen=50
nthreads=10

filt_qual=30
filt_depth=50

output_dir=/mnt/scratch/NGS/bratzveron/results

#входные аргументы
ID=$1
CHR=$2

#проверка наличия аргументов
if [[ -z "$ID" || -z "$CHR" ]]; then
    echo "usage: $0 sample_id chr_number"
    exit 1
fi
```

```

echo "запуск пайплайна для образца $ID, хромосома $CHR"

#проверка наличия входных файлов
forward_reads=$reads_dir/${ID}_1.fastq.gz
reverse_reads=$reads_dir/${ID}_2.fastq.gz
ref=$ref_dir/Homo_sapiens.GRCh38.dna.chromosome.${CHR}.fa

for file in "$forward_reads" "$reverse_reads" "$ref"; do
    if [[ ! -f "$file" ]]; then
        echo "ошибка: файл не найден: $file"
        exit 1
    fi
done

#создание выходных директорий
mkdir -p $output_dir/mapping
mkdir -p $output_dir/trimmed
mkdir -p $output_dir/vcf
mkdir -p $output_dir/fastqc

#шаг 1: индексация референса
echo "[1/11] индексация референса"
hisat2-build $ref $ref_dir/chr$CHR
samtools faidx $ref

#шаг 2: контроль качества исходных чтений
echo "[2/11] fastqc исходных чтений"
fastqc $forward_reads $reverse_reads -o $output_dir/fastqc

#шаг 3: триммирование чтений
echo "[3/11] триммирование trimmomatic"
TrimmomaticPE -$phred $forward_reads $reverse_reads \
    $output_dir/trimmed/trim_1_paired.fastq.gz \
    $output_dir/trimmed/trim_1_unpaired.fastq.gz \
    $output_dir/trimmed/trim_2_paired.fastq.gz \
    $output_dir/trimmed/trim_2_unpaired.fastq.gz \
    TRAILING:$trim_trailing MINLEN:$trim_minlen

#шаг 4: контроль качества после триммирования
echo "[4/11] fastqc после триммирования"
fastqc $output_dir/trimmed/trim* -o $output_dir/fastqc

#шаг 5: картирование на референс
echo "[5/11] картирование hisat2"
hisat2 -x $ref_dir/chr$CHR \

```

```

-1 $output_dir/trimmed/trim_1_paired.fastq.gz \
-2 $output_dir/trimmed/trim_2_paired.fastq.gz \
-p $nthreads --no-spliced-alignment \
> $output_dir/mapping/${ID}_map.sam 2>
$output_dir/mapping/map_log.txt

#шаг 6: сортировка и индексирование bam
echo "[6/11] сортировка и индексирование bam"
samtools sort -o $output_dir/mapping/${ID}_map.bam
$output_dir/mapping/${ID}_map.sam
samtools index $output_dir/mapping/${ID}_map.bam
samtools flagstat $output_dir/mapping/${ID}_map.bam >
$output_dir/mapping/analysed_bam.txt

#шаг 7: отбор чтений по хромосоме
echo "[7/11] отбор чтений для хромосомы $CHR"
samtools view -h -bS $output_dir/mapping/${ID}_map.bam $CHR >
$output_dir/mapping/${CHR}.chr.bam
samtools flagstat $output_dir/mapping/${CHR}.chr.bam >
$output_dir/mapping/${CHR}_analysed_bam.txt

#шаг 8: отбор правильно парных чтений
echo "[8/11] отбор правильно картированных пар"
samtools view -f 2 -bS $output_dir/mapping/${CHR}.chr.bam >
$output_dir/mapping/correct_${CHR}.bam
samtools index $output_dir/mapping/correct_${CHR}.bam

#шаг 9: пересечение с bed
echo "[9/11] пересечение bam с bed"
bedtools intersect -a $output_dir/mapping/correct_${CHR}.bam
-b $bed_file > $output_dir/mapping/exom_${CHR}.bam
bedtools intersect -a $output_dir/mapping/correct_${CHR}.bam
-b $bed_extended >
$output_dir/mapping/exom_extended_${CHR}.bam

#шаг 10: вызов вариантов
echo "[10/11] вызов вариантов bcftools"
bcftools mpileup -f $ref
$output_dir/mapping/correct_${CHR}.bam | \
bcftools call -mv -o $output_dir/vcf/variants.vcf
bcftools stats $output_dir/vcf/variants.vcf >
$output_dir/vcf/var_stats.txt

#шаг 11: фильтрация вариантов
echo "[11/11] фильтрация вариантов"

```

```
bcftools filter -i "QUAL>$filt_qual && DP>$filt_depth" \
    $output_dir/vcf/variants.vcf -o
$output_dir/vcf/filtered_variants.vcf
bcftools stats $output_dir/vcf/filtered_variants.vcf >
$output_dir/vcf/filt_var_stats.txt

echo "пайплайн завершён успешно"
echo "фильтрованный vcf: $output_dir/vcf/filtered_variants.vcf"
```

**Output:** создаются паки

```
/mnt/scratch/NGS/bratzveron/results/mapping
/mnt/scratch/NGS/bratzveron/results/trimmed
/mnt/scratch/NGS/bratzveron/results/vcf
/mnt/scratch/NGS/bratzveron/results/fastqc
```