

Задание 11

Подготовка референса

1) Получение референса

Создала папку для последовательности генома и индекса к программе для картирования с помощью hisat2 и скопировала в нее файл с вашей хромосомой. /mnt/scratch/NGS/anastasia.l/pr_11 2 папки genes и index

2) Индексация для hisat2

Проиндексировала референсный геном. Будет создавать индексную базу данных для выравнивания ридов на геномную информацию человека, содержащуюся в файле Homo_sapiens.GRCh38.dna.chromosome.4.fa. Выходные файлы базы данных будут иметь префикс prefix

Команда:

```
hisat2-build Homo_sapiens.GRCh38.dna.chromosome.4.fa prefix
```

Выдача: 8 файлов prefix.1-8.ht2

3) Индексация samtools.

Этот индекс позволяет эффективно находить и получать доступ к конкретным участкам генома, что является важным для многих биологических и генетических исследований.

Команда: samtools faidx Homo_sapiens.GRCh38.dna.chromosome.4.fa

Из полученного Homo_sapiens.GRCh38.dna.chromosome.4.fa.fai узнаем точное имя своей хромосомы и длину вашей хромосомы в нуклеотидах:

```
4 190214555 56 60 61
```

4-номер хромосомы/точное имя хромосомы

190214555-длина хромосомы в нуклеотидах

56: номер байта, с которого начинается сама нуклеотидная последовательность в fasta

60: число нуклеотидов в каждой строке в нуклеотидах

61: число байтов в каждой из строк

Чтения ДНК

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

1) SRR ID образца ДНК-чтений: SRR10720407

- 2) Ссылку на информацию об образце из NCBI:
<https://www.ncbi.nlm.nih.gov/sra/?term=SRR10720407>
- 3) Прибор для секвенирования: ILLUMINA (Illumina Genome Analyzer IIx)
- 4) Организм: Homo sapiens
- 5) Стратегию секвенирования (полногеномное, экзомное, таргетная панель):
 Whole-exome
- 6) Парноконцевые или одноконцевые чтения: PAIRED
- 7) Сколько чтений ожидается (spots) : 38,530,707


Проверка качества исходных чтений

Анализируем качество исходных чтений с помощью программы fastqc.
 Запустить fastqc можно с помощью команды fastqc file.fastq.gz
 Файлы папке quaity_check


Рассматриваем файлы : SRR10720407_2_fastqc.zip и SRR10720407_1_fastqc.zip

- 1) Какое количество пар чтений получилось: 38530707
- 2) Совпадает ли количество чтений у “прямых” чтений и “обратных” чтений: да, совпадает
- 3) Краткий комментарий качества пар чтений по результатам fastqc: качество чтений хорошее, только к концу становится чуть меньше 30 (ориентировалась относительно медиан красных и синих средних значений)

Прямые:




Обратные:




4) Краткий комментарий о длине ваших чтений по результатам fastqc – длина чтения 75

Прямые:




Обратные:




5) Краткий комментарий о качестве чтений: можем заключить, что здесь как и на первых рис в большинстве случаев качество больше 30

Прямые:



Обратные:



Фильтрация чтений

Используем команду TrimmomaticPE для обрезки и фильтрации последовательностей чтения (ридов) в парных файлах fastq.gz

Команда: TrimmomaticPE -phred33 SRR10720407_1.fastq.gz SRR10720407_2.fastq.gz trimmed_forward_paired.fastq.gz trimmed_reverse_paired.fastq.gz trimmed_forward_unpaired.fastq.gz trimmed_reverse_unpaired.fastq.gz TRAILING:20 MINLEN:50

Аргументы:


- **phred33**: указывает, что входные файлы в формате fastq используют кодировку качества Phred 33. Такая кодировка используется в большинстве современных прочтений Illumina
- **SRR10720407_1.fastq.gz**: первый файл
- **SRR10720407_2.fastq.gz**: второй файл
- **trimmed_forward/reverse_paired/unpaired.fastq.gz**: выходной файл, в котором содержатся обрезанные и отфильтрованные прочтения прямой/обратной цепей парных и непарных прочтений
- **TRAILING:20**: если качество последних нуклеотидов в ряде оказывается ниже 20, они будут удалены.
- **MINLEN:50**: Этот параметр указывает, что после всех операций обрезки и фильтрации, прочтения, имеющие длину меньше 50 нуклеотидов, будут удалены.

Проверка качества триммированных чтений


Анализируем качество чтений после обработки программой Trimmomatic с помощью программы fastQC.

- 1) Какое количество пар чтений осталось (paired) в штуках: 37276728
- 2) Какой процент пар чтений остался (paired) (процент от исходного количества пар чтений): 86.4
- 3) Краткий комментарий о сравнении качества чтений после триммирования: paired vs unpaired: качество непарных чтений заметно сильно хуже, чем качество парных


Прямые парные:




Прямые непарные:



Обратные парные:




Обратные непарные:




4) Краткий комментарий о сравнении качества чтений до и после триммирования (только paired) : качество особенно к концу значительно стало лучше

5) Как изменилась длина чтений после триммирования? также 75, а вот у непарных длина совсем изменилась, так как появились значительной величины пики на графиках


Прямые парные:




Прямые непарные:



Обратные парные:



Обратные непарные:



Задание 12

Картирование чтений на референсный геном

```
hisat2 -x ../reference/prefix -1../trimmed_forward_paired.fastq.gz -2  
../trimmed_reverse_paired.fastq.gz -p 10 --no-spliced-alignment > map1.sam 2>  
map1_log.txt
```

Аргументы:

- указываем путь до индекса референсного генома
- указываем путь до первого файла прямого и обратных чтений после обрезки и фильтрации ридов
- p 10:** аргумент указывает количество потоков (параллельных процессов), которые будут использоваться во время выполнения сопоставления.
- no-spliced-alignment:** Этот аргумент указывает HISAT2 не выполнять сопряженную сплайс-сайтовую выравнивание (splice site alignment) при поиске соответствий в геноме. (если работаем с референсными геномами без интронов или не хотим учитывать сплайс-сайты в сопоставлении)
- перенаправления стандартного вывода команды в файл **map.sam**
- 2> map_log.txt:** 2> используется для перенаправления вывода ошибок (stderr) команды в файл map1_log.txt.

Конвертация sam в bam

1. Сколько весит sam файл в Гб?- 267М (du -h map.sam)

Команда конвертации: samtools sort -o map.bam map.sam

2. Сколько весит bam файл в Гб? 86М (du -h map.bam)

Команда индексации получившийся bam файла: samtools index map.bam
(получаем:map.bam.bai)

Анализ bam файла

Выполняем анализ выравнивания ридов из файла map.bam с помощью инструмента SAMtools и сохраняет результат в файл analys_bam.txt

Команда: samtools flagstat map.bam > analys_bam.txt

Выдача analys_bam.txt:

1392336 + 0 in total (QC-passed reads + QC-failed reads)

1343762 + 0 primary

48574 + 0 secondary

0 + 0 supplementary

0 + 0 duplicates

0 + 0 primary duplicates

142559 + 0 mapped (10.24% : N/A)

93985 + 0 primary mapped (6.99% : N/A)

1343762 + 0 paired in sequencing

671881 + 0 read1

671881 + 0 read2

8 + 0 properly paired (0.00% : N/A)

6598 + 0 with itself and mate mapped

87387 + 0 singletons (6.50% : N/A)

0 + 0 with mate mapped to a different chr

0 + 0 with mate mapped to a different chr (mapQ>=5)

1) Сколько чтений картировано на референс в штуках? 142559

2) Сколько чтений картировано на референс в % от количества триммированных чтений? 10.24%

3) Сколько чтений картировано на референс в корректных парах в штуках? 8

4) Сколько чтений картировано на референс в корректных парах в % от количества триммированных чтений? 0.00%

Получение чтений, картированных на вашу хромосому

Мы извлекаем прочтения, относящиеся только к хромосоме номер 4 из файла `map.bam`, конвертирует его в формат BAM и сохраняет результат в файле `chr4_map.bam`

Команда: `samtools view -h -bS map.bam 4 > 1chr4_map.bam`

Аргументы:

1. **samtools view**- команда для просмотра или фильтрации данных в файле формата SAM или BAM.
2. **-h**- указывает samtools сохранить заголовок файла вместе с прочтениями. Без этого флага заголовок будет исключен из вывода.
3. **-bS**- указывает samtools конвертировать входной формат файла из SAM в BAM. Формат SAM - это текстовый формат, а формат BAM - бинарный формат, который занимает меньше места на диске и может быть быстро обработан.
4. **map.bam**- имя входного файла, который должен быть в формате SAM.
5. **4**-номер хромосомы которое указывает samtools извлечь только прочтения, относящиеся к этой конкретной хромосоме.
6. **> chr4_map.bam**- перенаправление вывода, которое указывает на сохранение результата в файл с именем `chr4_map.bam`.

Получение только правильно картированных пар чтений

1)Фильтруем прочтения в файле `chr4_map.bam` и сохраняет только те прочтения, которые являются правильно выровненными и имеют парные прочтения.

Команда: `samtools view -f 0x2 -bS 1chr4_map.bam > 1true_pairs_chr4_map.bam`

Аргументы:

1. **samtools view**- команда для просмотра или фильтрации данных в файле формата SAM или BAM.
2. **-f 0x2**- указывает samtools применить фильтр, чтобы только парные прочтения были включены в результат. **0x2** - соответствует "properly aligned" (правильно выравнено), который обозначает, что оба конца прочтения успешно выровнены.
3. **-bS**: это флаг, который указывает samtools конвертировать входной формат файла из SAM в BAM.
4. **chr4_map.bam**: это имя входного файла
5. **> 1true_pairs_chr4_map.bam**: это перенаправление вывода, которое указывает на сохранение результата в файл с именем `true_pairs_chr4_map.bam`.

2)А далее , используя команду ниже вычисляем статистические метрики для флагов прочтений в файле true_pairs_chr4_map.bam и сохраняет результаты в текстовом файле true_pairs.txt(информация о количестве прочтений, выровненных правильно, неправильно выровненных, пропущенных, дублированных и других статистических показателях качества выравнивания прочтений)

Команда:samtools flagstat true_pairs_chr4_map.bam > true_pairs.txt

Выдача true_pairs.txt:

```
28 + 0 in total (QC-passed reads + QC-failed reads)
8 + 0 primary
20 + 0 secondary
0 + 0 supplementary
0 + 0 duplicates
0 + 0 primary duplicates
28 + 0 mapped (100.00% : N/A)
8 + 0 primary mapped (100.00% : N/A)
8 + 0 paired in sequencing
4 + 0 read1
4 + 0 read2
8 + 0 properly paired (100.00% : N/A)
8 + 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)
```

1. Сколько чтений картировано на референс в корректных парах в штуках?-8

2. Сколько чтений картировано на референс в корректных парах в % от общего количества картированных чтений?-100.00%

3)Теперь проиндексирую файл(Индексирование BAM-файла позволяет ускорить поиск участков генома, которые соответствуют определенным координатам, и облегчает работу с данными. Создание индекса файла позволяет быстро определить положение прочтения внутри файла и ускоряет ряд операций, таких как поиск, обход и доступ к участкам генома)

Команда: samtools index true_pairs_chr4_map.bam

Получаем:true_pairs_chr4_map.bam.ba

Задание 13

1) Создаем файл покрытия на основе выравнивания данных секвенирования в формате BAM, с помощью команды `bcftools mpileup`, а затем команда `bcftools call` выполняет вариантный вызов на основе этого файла покрытия, сохраняя результаты в формате VCF

Команда: `bcftools mpileup -f Homo_sapiens.GRCh38.dna.chromosome.4.fa true_pairs_chr4_map.bam | bcftools call -mv -o var.vcf`

Аргументы:

- **bcftools mpileup** - инструмент для создания файлов покрытия для множества образцов на основе их выравнивания с использованием программы VCFtools.

- **-f Homo_sapiens.GRCh38.dna.chromosome.4.fa** - указывает на используемый файл референсной последовательности .

- **true_pairs_chr4_map.bam** - файл входных данных в формате BAM, который содержит секвенированные данные.

- В результате выполнения этой части команды генерируется файл, содержащий информацию о покрытии данных секвенирования.

- **bcftools call** - инструмент для вызова гетерозиготных и гомозиготных вариантов на основе секвенированных данных.

- **-mv** - указывает на вызов только тех вариантов, которые являются наиболее вероятными, и сохранение многоаллельных вариантов.

- **-o var.vcf** - указывает имя выходного файла (var.vcf), в котором будут сохранены полученные варианты в формате VCF.

Структура файл VCF (Variant Call Format):

1) Строки, начинающиеся с `##` и содержат метаданные и информацию о файле (информация о версии формата, использованных референсных последовательностях, форматах данных и других метаданных)

2) Строка, начинающаяся с `##CHROM:` (Хромосома, на которой находится вариант) и содержит 10 колонок:

- POS: Позиция варианта на хромосоме.

- ID: Идентификатор варианта (может быть пустым).

- REF: Референсная последовательность в данной позиции.

- ALT: Альтернативные последовательности (варианты) в данной позиции.

- QUAL: Качество вызова варианта.

- FILTER: Фильтр, примененный к варианту (пусто, если не было применено).

- INFO: Дополнительная информация о варианте, представленная в формате "ключ=значение"

Смотрим файл var.vcf :

```
##fileformat=VCFv4.2
##FILTER=<ID=PASS,Description="All filters passed">
##bcftoolsVersion=1.11+htslib-1.11-4
##bcftoolsCommand=mpileup -f chr.4.fa true_pairs_chr4_map.bam
##reference=file://chr.4.fa
##contig=<ID=4,length=190214555>
##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=DP,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=RPB,Number=1,Type=Float,Description="Mann-Whitney U test of Read Position Bias (bigger is better)">
##INFO=<ID=MQB,Number=1,Type=Float,Description="Mann-Whitney U test of Mapping Quality Bias (bigger is better)">
##INFO=<ID=BQB,Number=1,Type=Float,Description="Mann-Whitney U test of Base Quality Bias (bigger is better)">
##INFO=<ID=MQSB,Number=1,Type=Float,Description="Mann-Whitney U test of Mapping Quality vs Strand Bias (bigger is better)">
##INFO=<ID=SGB,Number=1,Type=Float,Description="Segregation based metric.">
##INFO=<ID=MQoF,Number=1,Type=Float,Description="Fraction of MQo reads (smaller is better)">
##FORMAT=<ID=PL,Number=G,Type=Integer,Description="List of Phred-scaled genotype likelihoods">
##FORMAT=<ID=GT,Number=1,Type=String,Description="Genotype">
##INFO=<ID=ICB,Number=1,Type=Float,Description="Inbreeding Coefficient Binomial test (bigger is better)">
##INFO=<ID=HOB,Number=1,Type=Float,Description="Bias in the number of HOMs number (smaller is better)">
##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=1.11+htslib-1.11-4
##bcftools_callCommand=call -mv -o var.vcf; Date=Sun Feb 4 00:03:30 2024
#CHROM POS ID REF ALT QUAL FILTER INFO FORMAT true_pairs_chr4_map.bam
4 124614845 . C A 9.88514 .
DP=1;SGB=-0.379885;MQoF=0;AC=2;AN=2;DP4=0,0,0,1;MQ=60 GT:PL 1/1:39,3,0
```

2)А теперь проанализируем var.vcf

С помощью утилиты bcftools результаты статистического анализа запишем в файл var_stats.txt

Команда:bcftools stats var.vcf > var_stats.txt

Смотрим файл var_stats.txt :

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

а) Сколько получилось вариантов?- 1

б) Сколько из полученных вариантов являются однонуклеотидными заменами?-1

с) Сколько получилось коротких вставок и делеций?-0

3)Фильтрация вариантов (будут оставлены только те варианты, у которых значение качества (QUAL) больше 30 и глубина покрытия (DP) больше 50)

Команда:bcftools filter -i'%QUAL>30 && DP>50' var1.vcf -o filt_variants.vcf

4)С помощью утилиты bcftools результаты статистического анализа запишем в файл filt_var_stats.txt

Команда:bcftools stats filt_variants.vcf > filt_var_stats.txt

Смотрим файл filt_var_stats.txt:

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

- a) Сколько осталось вариантов после фильтрации (в штуках и в процентах)? -0
- b) Сколько осталось однонуклеотидных замен (в штуках и в процентах)?-0
- c) Сколько осталось коротких вставок и делеций (в штуках и в процентах)?-0



Аннотация вариантов

Проаннотируйте полученные выше профильтрованные варианты с помощью сервиса VEP:

Category	Count
Variants processed	1
Variants filtered out	0
Novel / existing variants	0 (0.0) / 1 (100.0)
Overlapped genes	0
Overlapped transcripts	0
Overlapped regulatory features	0

Allele	Consequence	Existing variant
A	intergenic_variant	rs1387911427

A sequence variant located in the intergenic region, between genes

Задание 14

Задача: проанализировать одноконцевые чтения RNA-seq и составить экспрессионный профиль данного образца

Описание образца

Найходим ID нашего образца в базе NCBI (<https://www.encodeproject.org/>)

Укажите:

- 1) ID образца РНК-чтений ENCFF038OLY
- 2) Ссылка на информацию об образце:
<https://www.encodeproject.org/files/ENCFF038OLY/>
- 3) Организм и ткань : Fetal Muscle, Leg primary tissue, day 127, Homo sapiens
- 4) Стратегия секвенирования : RNA-Seq
- 5) парноконцевые или одноконцевые чтения: PAIRED
- 6) цепь-специфичность: no

Проверка качества исходных чтений


Проанализируем качество исходных чтений с помощью программы fastqc.

В данном случае у нас только один файл с чтениями: ENCFF038OLY.fastq.gz


Команда: fastqc ENCFF038OLY.fastq.gz

Проанализируем ENCFF038OLY_fastqc.zip:

- 1) Количество чтений 72517664
- 2) Краткий комментарий качества чтений по результатам fastqc: Среднее значение, медиана, интервалы между верхними и нижними квартилями вообще-то все в зеленой зоне , правда усы спускаются аж до 2 (см. рис ниже)



3) краткий комментарий о длине ваших чтений по результатам fastqc (картинка Sequence Length Distribution) - все имеют длину 36



Картирование чтений на референс

С помощью команды HISAT2 проводим картирование коротких прочтений RNA-Seq на референсный геном.

Команда: `hisat2 -x prefix -k 3 -U ENCFFo38OLY.fastq.gz > rna_map.sam 2> rna_map_log.txt`

Выдача файла rna_map_log.txt:

72517664 reads; of these:

72517664 (100.00%) were unpaired; of these:

67686406 (93.34%) aligned 0 times

4025941 (5.55%) aligned exactly 1 time

805317 (1.11%) aligned >1 times

6.66% overall alignment rate

а) Сколько чтений закартировалось на вашу хромосому? - Всего картировалось 4829676 чтений 6.66%

-Конвертируем sam bam:

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

-Индексируем :

Команда: `samtools index rna_map.bam - rna_map.bam.bai`

-Отбираем только те чтения, которые легли на хромосому:

Команда: `samtools view -h -bS rna_map.bam 4 > chr4_rna_map.bam`

-Изучаем файл с помощью samtools flagstat(Команда samtools flagstat используется для подсчета статистики флагов в файле BAM (Binary Alignment Map). Опция -O json указывает на формат вывода в формат JSON, который является структурированным форматом данных):

Команда:samtools flagstat -O json chr4_rna_map.bam > flagstat_chr4_rna.txt
Сколько чтений закартировалось на хромосому: "total": 6161222,

Поиск экспрессирующихся генов

Структура файл с геной разметкой в формате GFF (General Feature Format): состоит из строк, каждая из которых содержит 9 столбцов данных, плюс необязательные строки определения трека, такой формат позволяет описывать различные функции на геноме и связывать их с дополнительной информацией через атрибуты.

1. seqname - название хромосомы, названия хромосом могут быть указаны с или без префикса 'chr'.
2. source - название программы, которая сгенерировала эту функцию или источник данных (название базы данных или проекта).
3. feature - название типа функции, например, Gene, Variation, Similarity.
4. start - начальная позиция функции, начиная с 1.
5. end - конечная позиция функции, начиная с 1.
6. score - десятичное число.
7. strand - определяет, является ли цепь прямой (+) или обратной (-).
8. frame - одно из значений '0', '1' или '2'. '0' указывает, что первая база функции является первой базой кодона, '1' указывает, что вторая база является первой базой кодона и т.д.
9. attribute - точка с запятой разделяет список пар тег-значение, предоставляющих дополнительную информацию о каждой функции.

-Подсчет числа генов на хромосоме

Команда:grep '^4' *gtf | cut -f3 | grep 'gene' | wc -l

Получаем:2732

-Посчитаем для каждого гена число картированных на этот ген чтений с помощью htseq-count(htseq-count используется для подсчета количества выравниваний ридов на гены в файле BAM и ассоциировании их с аннотацией генов из файла GTF):

Команда:htseq-count -f bam -s no -m union -t gene rna_map.bam
Homo_sapiens.GRCh38.110.chr.gtf> htseq-count-out.txt

Опции аргумента:

Опция -f bam указывает, что входной файл - формат BAM

Опция -s no используется для обозначения отсутствия информации о направленности чтения (неориентированные чтения).

Опция -m union указывает, что для чтений, которые перекрывают несколько аннотированных областей, будет учитываться объединение этих областей при подсчете.

Опция -t gene указывает, что будут считаться только гены (не транскрипты или экзоны, а именно гены).

Смотрим последние 5 строк файла htseq-count-out.txt (всего было обработано :72517664 чтений):

__no_feature 379496- чтения, которые не попали в ген

__ambiguous 805372-не ясные

__too_low_aQual 0 - порог качества

__not_aligned 67686406 -в SAM файле чтения без выравнивания

__alignment_not_unique 805317- попали в несколько позиций

Попали на гены на 4 хромосоме = Всего на 4 хромосоме - __no_feature -
__ambiguous - __not_aligned-__alignment_not_unique = 72517664- 379496-
67686406-805372= 3384390 чтения попали в гены

