

利用 Python 进行生信分析 | 基础 + 实战

——Python for Bioinformatics



赵华男

2022 一起加油

项目一 序列文件的处理

序列储存格式的介绍

序列储存格式的介绍—FASTA 文件格式

● FASTA 格式

- 一种用于表示核苷酸序列或多肽序列的文本格式；其中碱基对或氨基酸用单个字母来表示
- 允许在序列前添加序列名及注释
- 该格式已成为生物信息学领域的一项标准

● FASTA 文件各行记录信息如下：

- 第一行
 - 由大于号">"开头的任意文字说明，用于序列标记
 - 为了保证后续分析软件能够区分每条序列，**单个序列的标识必须是唯一的**
- 第二行
 - 序列本身；只允许使用既定的核苷酸或氨基酸编码符号。
 - 通常核苷酸符号大小写均可，而氨基酸常用大写字母。
 - 注意有些程序对大小写有明确要求。一般每行 60-80 个字母。

```
1 >HWI-D00433:463:HNT7JBCXX:1:1101:19071:2193 1:N:0:TTCTCCAT
2 CCTACGGGACGCATCAGTGAGGAATATTGGTCAATGGACGCGAGTCTGAACCAGCCAA
3 AGCGTGAAGGATGAAGGCCCGATGGGTTGTAAACCTCTTTATCTGGGAATAAACGTC
4 CACGTGTGGTATTTTGTATGTACCATAAGAATAAGTATCGGCTAACTCCGTGCCAGCAC
5 CGCGGTAATACGGAGGATCCGAGCGTTATCCGGATTTATTGGGTTTAAAGGGTGCGCAC
6 CGGTCTGTTA
7 >HWI-D00433:463:HNT7JBCXX:1:1101:1713:2316 1:N:0:TTCTCCAT
8 CCTACGGGGTTTACCAGTAGGGAATCTTCCACAATGGGCGAAAGCCTGATTGAGCAAA
9 CGCGTGTTTTAAAGAGTCTTCGGATCGTAAACCTGTTGTTAGAGAAGAAAGTGCGGT
10 CGCGTAACTGTTACGTTTCTACTGTATCTAACAAGAAAGCACCGGCTAACTACGTTCC
```

序列储存格式的介绍—FASTA 文件格式

```
1 # legend server
2 cd /home/zhaohuanan/3.project/2022_Other_projects/2022-09-25_Prepared_data/FASTA
3 rsync -avzP rsync://hgdownload.cse.ucsc.edu/goldenPath/mm39/chromosomes/ .
4 # check一下md5
5 md5sum -c md5sum.txt
6
7 (base) PS C:\Users\vagrant\PythonForBioinformatics> rsync -avzP rsync://hgdownload.cse.
8 ucsc.edu/goldenPath/mm39/chromosomes/chrM.fa.gz .
9 receiving incremental file list
10 chrM.fa.gz
11      5,385 100%    5.14MB/s   0:00:00 (xfr#1, to-chk=0/1)
12
13 sent 43 bytes  received 5,492 bytes  299.19 bytes/sec
14 total size is 5,385  speedup is 0.97
15
16 # 接下来我们需要将genome生成一下,未确定的基因组区域暂不考虑,只看确定的基因组
17 # 测试命令
18 echo `seq 1 1 19` X Y M | awk 'BEGIN {printf "cat "}{for(i=1; i<=NF;i++){printf "chr"$i".fa.gz "}}'
19 # 写入genome文件
20 echo `seq 1 1 19` X Y M | awk 'BEGIN {printf "cat "}{for(i=1; i<=NF;i++){printf "chr"$i".fa.gz "}}' | \
21     sh > genome_ucsc_mm39.fa.gz
22 zcat genome_ucsc_mm39.fa.gz | grep -v N | less # linux/window
23 zcat < genome_ucsc_mm39.fa.gz | grep -v N | less # macos
```

序列储存格式的介绍—FASTQ 文件格式

● 第一行

- 以 @ 开头
- 后面是 reads 的 ID 以及其他信息
- 例如下一页例中 HWUSI-EAS100R 代表 Illumina 设备名称,
- 6 代表 flowcell 中的第六个 lane, 73 代表第六个 lane 中的第 73 个 tile
- 941:1973 代表该 read 在该 tile 中的 x:y 坐标信息;
- #0, 若为多样本的混合作为输入样本, 则该标志代表样本的编号, 用来区分个样本中的 reads/
- /1 代表 paired end 中的前一个 read。

● 第二行

- read 的序列
- 紧接着下面两行代表该 read 的质量

● 第三行

- 以“+”开头, 跟随着该 read 的名称 (一般于 @ 后面的内容相同), 但有时可以省略, 但“+”一定不能省

序列储存格式的介绍—FASTQ 文件格式

● 第四行

- 代表 reads 的质量。这一行可以详细说一下!
- Illumina 测序仪是按照荧光信号来判断所测序的碱基是哪一种的, 例如红黄蓝绿分别对应 ATCG, 那么一旦出现一个紫色的信号该怎么判断呢?
- 因此对每个结果都有一个概率的问题。起初 sanger 中心用 Phred quality score 来衡量该 read 中每个碱基的质量, 既-10lgP #(lg 意为 log10)
 - 其中 P 代表该碱基被测序错误的概率
 - 如果该碱基测序出错的概率为 0.001, 则 Q 应该为 30, 那么 $30+33=63$, 那么 63 对应的 ASCII 码为 '?', 则在第四行中该碱基对应的质量代表值即为 '?'
 - ASCII <https://baike.baidu.com/item/ASCII>

```

1 @SEQ_ID
2 GATTGGGGTTCAAAGCAGTATCGATCAAAATAGTAAATCCATTTGTTCAAACTCACAGTTT
3 +
4 !'*( ((( (****))%%++)(%%%) .1***-+*' '))**55CCF
5
6 # 例如在NCBI看到的FASTQ格式如下
7 @HWUSI-EAS100R:6:73:941:1973#0/1
8 GATTGGGGTTCAAAGCAGTATCGATCAAAATAGTAAATCCATTTGTTCAAACTCACAGTT
9 +HWUSI-EAS100R:6:73:941:1973#0/1
10 !'*( ((( (****))%%++)(%%%) .1***-+*' '))**55CCF
  
```

序列储存格式的介绍-FASTQ 文件格式

[illegible]

FASTQ 文件的操作

FASTQ 文件的操作

● FASTQ 文件的操作

- 读取 FASTQ 文件并以 FASTA 格式输出
- 解析 FASTQ 的质量值, 计算 Q30 比例
- 根据 FastQC 报告对 FASTQ 文件进行截取
- 根据 FastQC 报告, 过滤低质量的 lane,tile 数据

FASTA 文件的操作

FASTA 文件的操作

● FASTA 文件的操作

- 读取 FASTA 文件，并将其中 U 替换成 T
- 读取 FASTA 文件，并输出反向互补序列
- 计算基因组序列的长度
- 计算基因组各染色体的平均 GC 含量
- 计算基因组中 N 的总长度 (effective length)

Docstring-reST

```
1 def func(arg1, arg2):
2     """Summary line.
3
4     Extended description of function.
5
6     :param int arg1: Description of arg1.
7     :param str arg2: Description of arg2.
8     :raise: ValueError if arg1 is equal to arg2
9     :return: Description of return value
10    :rtype: bool
11
12    :example:
13
14    >>> a=1
15    >>> b=2
16    >>> func(a,b)
17    True
18    """
19
20    if arg1 == arg2:
21        raise ValueError('arg1 must not be equal to arg2')
22
23    return True
```

Docstring-Google Style

```
1 def func(arg1, arg2):
2     """Summary line.
3
4     Extended description of function.
5
6     Args:
7         arg1 (int): Description of arg1
8         arg2 (str): Description of arg2
9
10    Returns:
11        bool: Description of return value
12
13    Raises:
14        AttributeError: The 'Raises' section is a list of all
15                        exceptions that are relevant to the interface.
16        ValueError: If 'arg2' is equal to 'arg1'.
17
18    Examples:
19        Examples should be written in doctest format, and should
20        illustrate how to use the function.
21        >>> a=1
22        >>> b=2
23        >>> func(a,b)
24        True
25    """
```

```
1 if arg1 == arg2:
2     raise ValueError(
3         'arg1 must not be equal to arg2'
4     )
5
6 return True
```

Docstring-Numpy Style

```

1 def func(arg1, arg2):
2     """Summary line.
3
4     Extended description of function.
5
6     Parameters
7     -----
8     arg1 : int
9         Description of arg1
10    arg2 : str
11        Description of arg2
12
13    Returns
14    -----
15    bool
16        Description of return value
17
18    Raises
19    -----
20    AttributeError
21        The ''Raises'' section is a list of all exceptions
22        that are relevant to the interface.
23    """

```

```

1     """
2     ValueError
3         If 'arg2' is equal to 'arg1'.
4
5     See Also
6     -----
7     otherfunc: some other related function
8
9     Examples
10    -----
11    These are written in doctest format, and should
12    use the function.
13
14    >>> a=1
15    >>> b=2
16    >>> func(a,b)
17    True
18    """
19
20    if arg1 == arg2:
21        raise ValueError(
22            'arg1 must not be equal to arg2'
23        )
24    return True

```

Q & A!

Thank you!