# Reference genomes and common file formats

## Dóra Bihary

MRC Cancer Unit, University of Cambridge

CRUK Functional Genomics Workshop September 2017



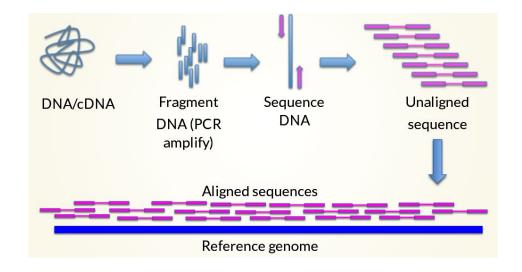


#### **Overview**

- Reference genomes and GRC
- Fasta and FastQ (unaligned sequences)
- SAM/BAM/CRAM (aligned sequences)
- Summarized genomic features
  - BED (genomic intervals)
  - GFF/GTF (gene annotation)
  - Wiggle files, BEDgraphs, BigWigs (genomic scores)

## Why do we need to know about reference genomes?

- Allows for genes and genomic features to be evaluated in their genomic context.
  - Gene A is close to gene B
  - Gene A and gene B are within feature C
- Can be used to align shallow targeted high-throughput sequencing to a pre-built map of an organism



#### **Genome Reference Consortium (GRC)**

- Most model organism reference genomes are being regularly updated
- Reference genomes consist of a mixture of known chromosomes and unplaced contigs called Genome Reference Assembly
- Genome Reference Consortium:
  - A collaboration of institutes which curate and maintain the reference genomes of 4 model organisms:
    - Human GRCh38.p11 (June 2017)
    - Mouse GRCm38.p5 (June 2017)
    - Zebrafish GRCz10 (May 2015)
    - Chicken Gallus\_gallus-5.0 (Dec 2016)
  - Latest human assembly is GRCh38, patches add information to the assembly without disrupting the chromosome coordinates
- Other model organisms are maintained separately, like:
  - o Drosophila Berkeley Drosophila Genome Project

#### **Overview**

- Reference genomes and GRC
- Fasta and FastQ (unaligned sequences)
- SAM/BAM/CRAM (aligned sequences)
- Summarized genomic features
  - BED (genomic intervals)
  - GFF/GTF (gene annotation)
  - Wiggle files, BEDgraphs, BigWigs (genomic scores)

#### The reference genome

- A reference genome is a collection of contigs
- A contig refers to overlapping DNA reads encoded as A, G, C, T or N
- Typically comes in FASTA format:
  - o ">" line contains information on contig
  - Following lines contain contig sequences

>gi|568815581:c7687550-7668402 Homo sapiens chromosome 17, GRCh38.p7 Primary Assembly

## **Unaligned sequences - FastQ**

 Unaligned sequence files generated from HTS machines are mapped to a reference genome to produce aligned sequence

FastQ (unaligned sequences) → SAM (aligned sequences)

FastQ: FASTA with quality

```
@HS2000-887_89:5:1101:1595:156011/1

ACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCTAACCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAA
```

- "@" followed by identifier
- Sequence information
- "+"
- Quality scores encodes as ASCI

## Unaligned sequences - FastQ header

```
0 @HS2000-887_89:5:1101:1595:156011/1
2 ACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCTAACCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCT
```

- Header for each read can contain additional information
  - HS2000-887\_89 Machine name
  - o 5 Flowcell lane
  - /1 Read 1 or 2 of pair

#### **Unaligned sequences - FastQ qualities**

```
@HS2000-887_89:5:1101:1595:156011/1

ACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAACCCTAAC
```

- Quality scores come after the "+" line
- Quality (Q) is proportional to  $-\log_{10}$  probability of sequence base being wrong (e):

$$Q = -\log_{10}(e)$$

- Encoded in ASCII to save space
- Used in quality assessment and downstream analysis
- For further information: <a href="https://en.wikipedia.org/wiki/FASTQ\_format">https://en.wikipedia.org/wiki/FASTQ\_format</a>

#### **Overview**

- Reference genomes and GRC
- Fasta and FastQ (unaligned sequences)
- SAM/BAM/CRAM (aligned sequences)
- Summarized genomic features
  - BED (genomic intervals)
  - GFF/GTF (gene annotation)
  - Wiggle files, BEDgraphs, BigWigs (genomic scores)

- SAM Sequence Alignment Map
- Standard format for sequence data
- Recognised by majority of software and browsers

#### SAM header

- SAM header contains information on alignment and contigs used
- @HD Version number and sorting information
- @SQ Contig/Chromosome name and length of sequence

```
QHD VN:1.4 SO:coordinate
@SQ SN:chr10
@SQ SN:chr11
@SQ SN:chr12
@SQ SN:chr13
@SQ SN:chr15
@SQ SN:chr16
@SQ SN:chr17
   SN:chr2 LN:182113224
@SQ SN:chr5 LN:151834684
@SQ SN:chr6 LN:149736546
@SQ SN:chr7 LN:145441459
@SQ SN:chr8 LN:129401213
@SQ SN:chr9 LN:124595110
@SQ SN:chrM LN:16299
@SQ SN:chrX LN:171031299
@SQ SN:chrY LN:91744698
```

#### SAM aligned reads

```
HS2000-905_68:3:1307:14091:6825 137 chr2
13894
                                   92045101
                                           254 28M1D72M
     ATAGACAACTAACAGAGTGGGAACCCTGCCCCTGAACCCTGACCCCTAACCCCTGACCCTGACCACTAACCCCTGGCCATAACCCCTAACCCCTA
     BC:Z:0 XD:Z:11T16^A$5A1C45A18 SM:i:328
                                   AS: 1:0
13895
     HS2000-905_68:1:1305:12812:167908 147 chr2
                                      92045105
                                              254 100M
                                                         92044908
     CDDDCCDDDBDBBDDDDCCCCDDDCCDDDDB?DEEEEC@FFFFHGHGIGDC=IIIJIHGJJJHEDJJJIGF?IJJIIIHJJIGFCJJHHHFHFFFDD=aB
     AM:i:0 BC:Z:0 XD:Z:A3CT1TCA1AGTGGGAACC1TGAC4A14C8C12A13A18
13896 HS2000-905_68:2:2107:9712:70649 163 chr2
                                           254 100M
                                                              301
                                   92045106
     CAACTATCAGAGGGGGAACCCTGACCCCTAACCCCTGACCCCTAACCCCTAACCCCTGAGCACTAACCCCTGACCATAACCCCTAACCTCCAACCC
     BC:Z:0 XD:Z:12T51C27C1T5
                        SM: i: 346
                                AS: 1:797
```

- Contains read and alignment information and location
  - Read name
  - Sequence of read
  - Encoded sequence quality

#### SAM aligned reads

```
HS2000-905_68:3:1307:14091:6825 137 chr2
13894
                                   92045101
     ATAGACAACTAACAGAGTGGGAACCCTGCCCCTGAACCCTGACCCCTAACCCCTGACCCTGACCACTAACCCCTGGCCATAACCCCTAACCCCTA
     BC:Z:0 XD:Z:11T16^A$5A1C45A18 SM:i:328
13895
     HS2000-905 68:1:1305:12812:167908
                             147 chr2
                                      92045105
                                              254 100M
                                                                 -297
     TCAAAGAGTGGGACCCCTGACCCTGACCCTGACCCCTGACCCTAACCTCTGACCCCTAACCCCTAACCCCTAACCCCTAACCCCTAACCCCTAACCCCTAACCCCTAACCC
     CDDDCCDDDBDBBDDDDCCCCDDDCCDDDDB?DEEEEC@FFFFHGHGIGDC=IIIJIHGJJJHEDJJJIGF?IJJIIIHJJIGFCJJHHHFHFFFDD=@B
     AM:i:0 BC:Z:0 XD:Z:A3CT1TCA1AGTGGGAACC1TGAC4A14C8C12A13A18
13896 HS2000-905_68:2:2107:9712:70649 163 chr2
                                           254 100M
                                                              301
     BC:Z:0 XD:Z:12T51C27C1T5
                        SM:1:346
                                AS: 1:797
```

- Chromosome to which the read aligns
- Position in chromosome to which 5' end of the read aligns
- Alignment information "Cigar string"
  - 100M Continuous match of 100 bases
  - 28M1D72M 28 bases continuously match, 1 deletion from reference, 72 base match

#### SAM aligned reads

```
HS2000-905_68:3:1307:14091:6825 137 chr2
13894
                                  92045101
                                          254 28M1D72M
     ATAGACAACTAACAGAGTGGGAACCCTGCCCCTGAACCCTGACCCCTAACCCCTGACCCTGACCACTAACCCCTGGCCATAACCCCTAACCCCTA
     BC:Z:0 XD:Z:11T16^A$5A1C45A18 SM:1:328
     HS2000-905 68:1:1305:12812:167908
                                     92045105
                                             254 100M
13895
     CDDDCCDDDBDBBDDDDCCCCDDDCCDDDDB?DEEEEC@FFFFHGHGIGDC=IIIJIHGJJJHEDJJJIGF?IJJIIIHJJIGFCJJHHHFHFFFDD=@B
     AM:i:0 BC:Z:0 XD:Z:A3CT1TCA1AGTGGGAACC1TGAC4A14C8C12A13A18
13896 HS2000-905 68:2:2107:9712:70649 163 chr2
                                  92045106
                                          254 100M
                                                             301
     CAACTATCAGAGGGGGAACCCTGACCCCTAACCCCTGACCCCTAACCCCTAACCCCTGACCATAACCCCTGACCATAACCCCTAACCTCAACCC
     BC:Z:0 XD:Z:12T51C27C1T5 SM:i:346
                                AS: 1:797
```

- Bit flag TRUE/FALSE for pre-defined read criteria, like: is it paired? duplicate?
  - https://broadinstitute.github.io/picard/explain-flags.html
- Paired read position and insert size
- User defined flags

## Compressed aligned sequences - BAM and CRAM format

- SAM files can be large, so to save space people usually store some compressed versions of them instead:
  - BAM files
    - Binary SAM files
    - You also need to store an index file
  - CRAM files
    - Another way to compress alignment files designed by the EBI
    - The compression is driven by the reference the sequence data is aligned to, so it is very important that the exact same reference sequence is used for compression and decompression
    - Typically 40-50% space saving compared to BAM files
    - Full compatibility with BAM files
    - For further information: <a href="http://samtools.github.io/hts-specs/">http://samtools.github.io/hts-specs/</a>

#### **Overview**

- Reference genomes and GRC
- Fasta and FastQ (unaligned sequences)
- SAM/BAM/CRAM (aligned sequences)
- Summarized genomic features
  - BED (genomic intervals)
  - GFF/GTF (gene annotation)
  - Wiggle files, BEDgraphs, BigWigs (genomic scores)

## Summarised genomic features formats

- After alignment, sequence reads are typically summarised into scores over/within genomic intervals
  - o BED genomic intervals with additional information
  - Wiggle files, BEDgraphs, BigWigs genomic intervals with scores
  - GFF/GTF genomic annotation with information and scores

# **BED format - genomic intervals**

1	chr7	127471196	127472363
2	chr7	127472363	127473530
3	chr7	127473530	127474697
4	chr7	127474697	127475864
5	chr7	127475864	127477031
6	chr7	127477031	127478198
7	chr7	127478198	127479365
8	chr7	127479365	127480532
9	chr7	127480532	127481699

1	chr7	127471196	127472363	Pos1	10	+
2	chr7	127472363	127473530	Pos2	11	+
3	chr7	127473530	127474697	Pos3	20	+
4	chr7	127474697	127475864	Pos4	10	+
5	chr7	127475864	127477031	Neg1	98	_
6	chr7	127477031	127478198	Neg2	10	_
7	chr7	127478198	127479365	Neg3	67	_
8	chr7	127479365	127480532	Pos5	20	+
9	chr7	127480532	127481699	Neg4	50	-

- BED3 3 tab separated columns
  - Chromosome
  - Start
  - o End
- Simplest format

- BED6 6 tab separated columns
  - o Chromosome, start, end
  - Identifier
  - Score
  - Strand ("." stands for strandless)

## Wiggle format - genomic scores

#### Variable step Wiggle format

- 1 variableStep chrom=chr2
  2 300701 12.5
  3 300702 12.5
  4 300703 12.5
  5 300704 12.5
  6 300705 12.5

  9 variableStep chrom=chr2 span=5
  10 300701 12.5
- Information line
  - Chromosome
  - (Span default=1, to describe contiguous positions with same value)
- Each line contains:
  - Start position of the step
  - Score

#### Fixed step Wiggle format

- 15 fixedStep chrom=chr3 start=400601 step=100
  16 11
  17 22
  18 33
  21 fixedStep chrom=chr3 start=400601 step=100 span=5
  22 11
  23 22
  24 33
- Information line
  - Chromosome
  - Start position of first step
  - Step size
  - (Span default=1, to describe contiguous positions with same value)
- Each line contains:
  - Score

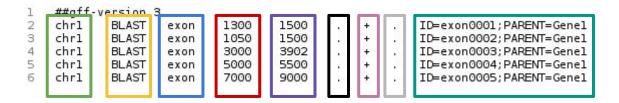
## bedGraph format - genomic scores

- BED-like format
- Starts as a 3 column BED file (chromosome, start, end)
- 4th column: score value

1	chr1	10001	10002	1
2	chr1	10003	10010	10
3	chr1	10011	10020	11
4	chr1	10021	10040	10
5	chr1	10041	10050	2
6	chr1	10051	99999	0

## **GFF** - genomic annotation

Stores position, feature (exon) and meta-feature (transcript/gene) information



- Columns:
  - Chromosome
  - Source
  - Feature type
  - Start position
  - End position
  - Score
  - Strand
  - Frame 0, 1 or 2 indicating which base of the feature is the first base of the codon
  - Semicolon separated attribute: ID (feature name);PARENT (meta-feature name)

#### Saving time and space - compressed file formats

- Many programs and browsers deal better with compressed, indexed versions of genomic files
  - SAM -> BAM (.bam and index file of .bai)
  - SAM/BAM -> CRAM (.cram file with the reference)
  - BED -> bigBed (.bb)
  - Wiggle and bedGraph -> bigWig (.bw/.bigWig)
  - BED and GFF -> (.gz and index file of .tbi)

## Getting help and more information

- UCSC file formats
  - https://genome.ucsc.edu/FAQ/FAQformat.html
- IGV file formats
  - http://software.broadinstitute.org/software/igv/FileFormats
- Sanger file formats
  - o <a href="http://gmod.org/wiki/GFF3">http://gmod.org/wiki/GFF3</a>

# Acknowledgement

Tom Carroll

http://mrccsc.github.io/genomic\_formats/genomicFileFormats.html#/