

2015年度第一回 バイオインフォマティクス実習

Bowtieを用いたシーケンスデータのマッピング

Cygwin

- cygwin
windows上で動作するUnix環境の一つ
- www.cygwin.comで配布しているsetup.exeをダウンロード
- 実行してインストール
- Cygwinターミナル(端末)を起動
スタートメニュー → 2.ネットワークツール → 仮想UNIX端末(cygwin64)

作業ディレクトリ作成

Cygwin - □ X

```
$ cd /cygdrive/z/デスクトップ ↵
$ mkdir work_space ↵
$ cd work_space ↵
```

ファイルの取得

- Index用ゲノムreference

マウス染色体1番

<http://hgdownload.cse.ucsc.edu/goldenPath/mm10/chromosomes/chr1.fa.gz>

- シーケンスデータ

GEO データベースaccession number GSE65976

SRR1508230.sra ,SRR1508234.sra

SRR1805875.sra, SRR1805876.sra

課題配布フォルダ → bioinfojisuu → chr1.fa

part_SRR1805875.fastq

Bowtie

- マッピングツールの一つ
- Burrows Wheeler transformを利用している
- 高速である
- メモリの消費は少ない
- 並列化に対応している

Bowtie

- <http://bowtie-bio.sourceforge.net/index.shtml>

Latest releaseから最新版をダウンロード

bowtie-1.1.1-mingw.x86_64.zip

展開して使用

課題配布フォルダのbowtie-1.1.1フォルダを各自のデスクトップに
コピー

Bowtieのコマンド1 Index作成

Cygwin - X

```
$bowtie-build -f chr1.fa mm10_chr1 ↵
```

bowtie-build -f リファレンスファイル名 インデックス名
referenceのゲノム配列をBurrows-Wheeler変換を使ってインデックス化する
mm10_chr1.1.ebwt
mm10_chr1.2.ebwt
mm10_chr1.3.ebwt
mm10_chr1.4.ebwt
mm10_chr1.rev.1.ebwt
mm10_chr1.rev.2.ebwt
6個のファイルが作成される

Burrows Wheeler transform

- The BWT applies a reversible transformation to a block of input text. The transformation does not itself compress the data, but reorders it to make it easy to compress with simple algorithms such as move-to-front coding.

Burrows M, Wheeler DJ (1994) A block-sorting lossless data compression algorithm. Technical report 124. Palo Alto, CA:
Digital Equipment Corporation.

Burrows Wheeler transform

original

$X = \text{abracadabra}$

末尾に\$を付ける

左に一文字ずつシフトして

ローテーション

| | | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|----|
| a | b | r | a | c | a | d | a | b | r | a | \$ |
| b | r | a | c | a | d | a | b | r | a | \$ | a |
| r | a | c | a | d | a | b | r | a | \$ | a | b |
| a | c | a | d | a | b | r | a | \$ | a | b | r |
| c | a | d | a | b | r | a | \$ | a | b | r | a |
| a | d | a | b | r | a | \$ | a | b | r | a | c |
| d | a | b | r | a | \$ | a | b | r | a | c | a |
| a | b | r | a | \$ | a | b | r | a | c | a | d |
| b | r | a | \$ | a | b | r | a | c | a | d | a |
| r | a | \$ | a | b | r | a | c | a | d | a | b |
| a | \$ | a | b | r | a | c | a | d | a | b | r |
| \$ | a | b | r | a | c | a | d | a | b | r | a |

Burrows Wheeler transform

| | F | | | | | | | | | | | | L |
|--|----|----|----|----|----|----|----|----|----|----|----|----|---|
| アルファベット順にソート \$はaよりも先 $BWT(X) = ard\$rcaaaabb$ | \$ | a | b | r | a | c | a | d | a | b | r | a | |
| | a | \$ | a | b | r | a | c | a | d | a | b | r | r |
| | a | b | r | a | \$ | a | b | r | a | c | a | d | |
| | a | b | r | a | c | a | d | a | b | r | a | \$ | |
| | a | c | a | d | a | b | r | a | \$ | a | b | r | |
| | a | d | a | b | r | a | \$ | a | b | r | a | c | |
| | b | r | a | \$ | a | b | r | a | c | a | d | a | |
| | b | r | a | c | a | d | a | b | r | a | \$ | a | |
| | c | a | d | a | b | r | a | \$ | a | b | r | a | |
| | d | a | b | r | a | \$ | a | b | r | a | c | a | |
| | r | a | \$ | a | b | r | a | c | a | d | a | b | |
| | r | a | c | a | d | a | b | r | a | \$ | a | b | |

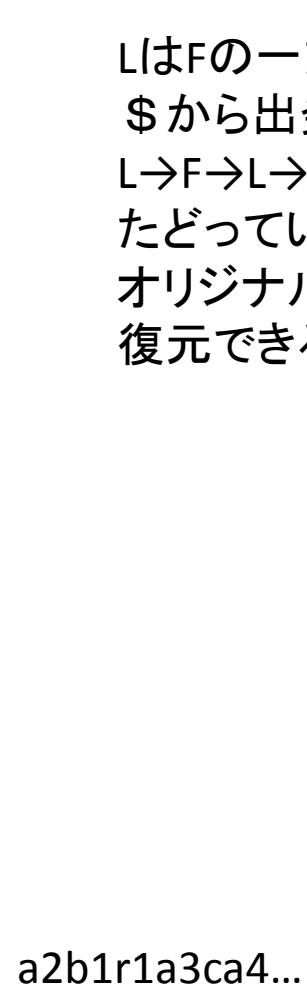
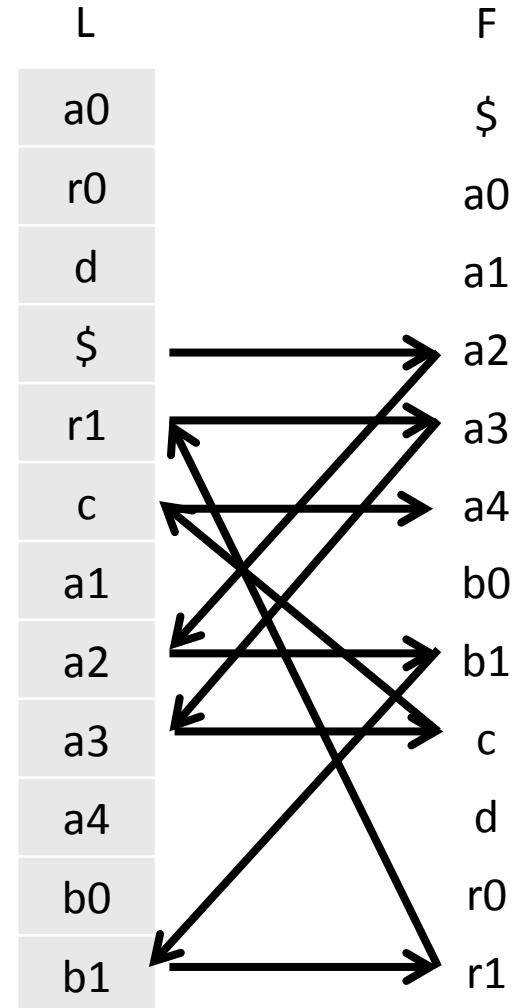
Burrows Wheeler 逆変換

(複数個ある
文字には番号を
付けてある)

| L |
|----|
| a0 |
| r0 |
| d |
| \$ |
| r1 |
| c |
| a1 |
| a2 |
| a3 |
| a4 |
| b0 |
| b1 |

辞書式に
並べ替え

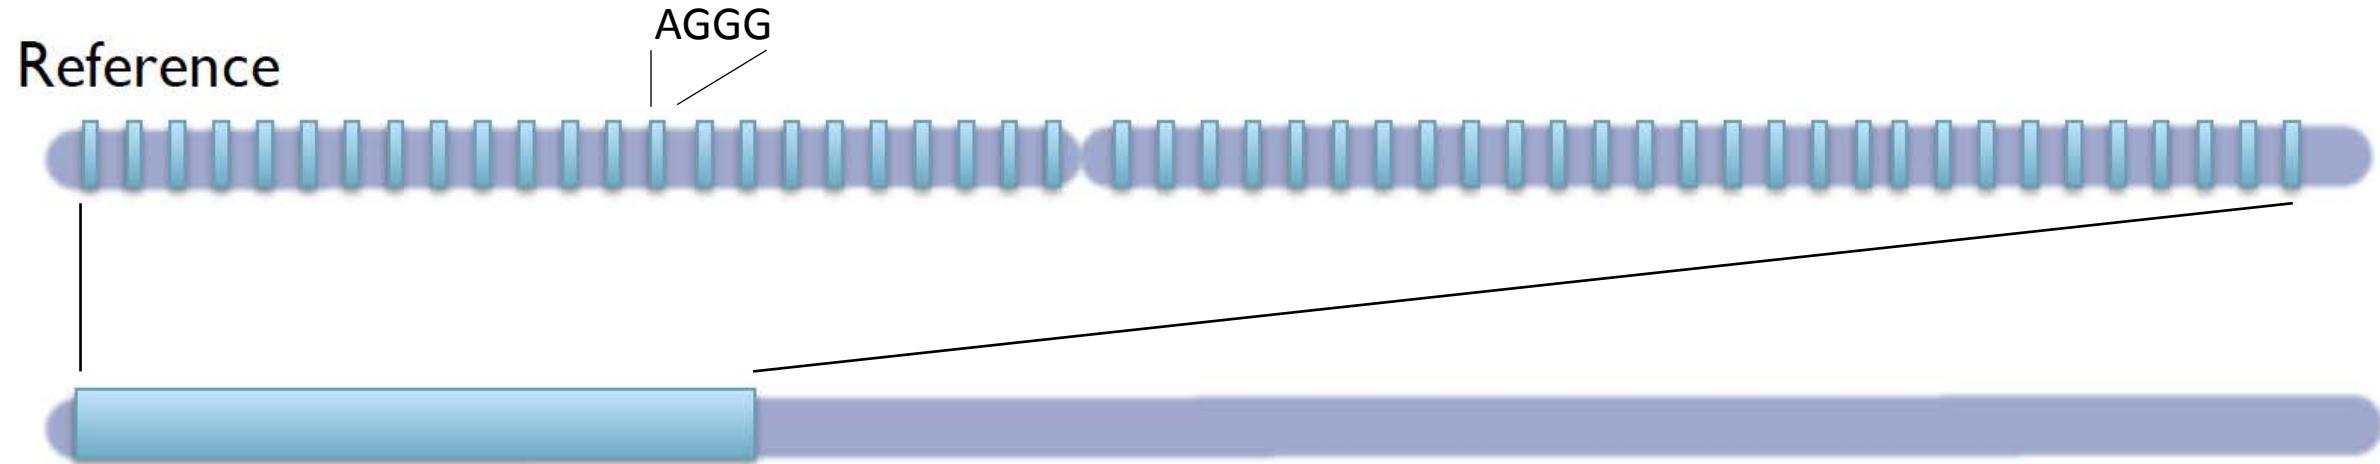
| F |
|----|
| \$ |
| a0 |
| a1 |
| a2 |
| a3 |
| a4 |
| b0 |
| b1 |
| c |
| d |
| r0 |
| r1 |



LはFの一文字前
\$から出発して
L→F→L→L...と
たどっていくと
オリジナルの文字列を
復元できる

a2b1r1a3ca4...

BWTの利点



BWT(Reference)

同じ文字が固まる傾向がある
検索しやすい
簡単に復元できる

F L

GGGA ~ A
GGGC ~ A
GGGT ~ A
...

マッピング

Cygwin - X

```
$bowtie -m 1 -v 2 -a --strata --best -S mm9/mm9 part_SRR1805875.fastq  
mm10_chr1 SRR1805875.sam
```

bowtie (option) 参照インデックス名 fastqファイル名 出力ファイル名

- m 1 : 1リードを1か所にマッピングする
- v 2 : ミスマッチを2個まで許容する
- a : 候補の配列を全て列挙する
- best : ベストマッチの場所にマッピング
- strata :
- S : 結果をsamファイル形式で出力

Burrows Wheeler transform

| original | 0 | c | t | g | a | a | a | c | t | g | g | t | \$ | | |
|---------------------------|----|----|----|----|----|----|----|----|----|---|----|---|----|---|---|
| $X = \text{ctgaaactgggt}$ | 1 | t | g | a | a | a | a | c | t | g | g | t | \$ | c | |
| | 2 | G | a | a | a | a | c | t | g | g | g | t | \$ | c | t |
| | 3 | a | a | a | c | t | g | g | g | t | \$ | c | t | g | |
| | 4 | a | a | c | t | g | g | t | \$ | c | t | g | a | | |
| | 5 | a | c | t | g | g | t | \$ | c | t | g | a | a | | |
| | 6 | c | t | g | g | t | \$ | c | t | g | a | a | a | | |
| | 7 | t | g | g | t | \$ | c | t | g | a | a | a | c | | |
| | 8 | g | g | t | \$ | c | t | g | a | a | a | c | t | | |
| | 9 | g | t | \$ | c | t | g | a | a | a | c | t | g | | |
| | 10 | t | \$ | c | t | g | a | a | a | c | t | g | g | | |
| | 11 | \$ | c | t | g | a | a | a | c | t | g | g | t | | |

Burrows Wheeler transform

$X = ctgaaaactgggt\$\n$

$BWT(X) = tgaa\$attggcc$

| | | | | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| 0 | \$ | c | t | g | a | a | a | c | t | g | g | t | 11 |
| 1 | a | a | a | c | t | g | g | t | \$ | c | t | g | 3 |
| 2 | a | a | c | t | g | g | t | \$ | c | t | g | a | 4 |
| 3 | a | c | t | g | g | t | \$ | c | t | g | a | a | 5 |
| 4 | c | t | g | a | a | a | c | t | g | g | t | \$ | 0 |
| 5 | c | t | g | g | t | \$ | c | t | g | a | a | a | 6 |
| 6 | g | a | a | a | c | t | g | g | t | \$ | c | t | 2 |
| 7 | g | g | t | \$ | c | t | g | a | a | a | c | t | 8 |
| 8 | g | t | \$ | c | t | g | a | a | a | c | t | g | 9 |
| 9 | t | \$ | c | t | g | a | a | a | c | t | g | g | 10 |
| 10 | t | g | a | a | a | c | t | g | g | t | \$ | c | 1 |
| 11 | t | g | g | t | \$ | c | t | g | a | a | a | c | 7 |

Backward Search

ctgaaactgg\$から
配列“ctgg”を検索

$\underline{R}(W)$: 文字Wが出現する
最初の列

$\bar{R}(W)$: 文字Wが出現する
最後の列

$$\underline{R}(g) = 6$$

$$\bar{R}(g) = 8$$

| | | | | | | | | | | | | | | |
|---|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| | 0 | \$ | c | t | g | a | a | c | t | g | g | t | 11 | |
| | 1 | a | a | a | c | t | g | g | t | \$ | c | t | 3 | |
| | 2 | a | a | c | t | g | g | t | \$ | c | t | g | 4 | |
| | 3 | a | c | t | g | g | t | \$ | c | t | g | a | 5 | |
| | 4 | c | t | g | a | a | a | c | t | g | g | t | \$ | 0 |
| | 5 | c | t | g | g | t | \$ | c | t | g | a | a | a | 6 |
| → | 6 | g | a | a | a | c | t | g | g | t | \$ | c | t | 2 |
| | 7 | g | g | t | \$ | c | t | g | a | a | a | c | t | 8 |
| → | 8 | g | t | \$ | c | t | g | a | a | a | a | c | t | 9 |
| | 9 | t | \$ | c | t | g | a | a | a | c | t | g | g | 10 |
| | 10 | t | g | a | a | a | c | t | g | g | t | \$ | c | 1 |
| | 11 | t | g | g | t | \$ | c | t | g | a | a | a | c | 7 |

Backward Search

$$\underline{R}(aW) = C(a) + O(a, \underline{R}(W) - 1) + 1$$

$$\overline{R}(aW) = C(a) + O(a, \overline{R}(W))$$

$C(a)$: a よりもアルファベット的に
小さい文字数

$O(a, i)$: BWT列内で i 列目までの
 a の数

$$\underline{R}(gg) = C(g) + O(g, \underline{R}(g) - 1) + 1$$

$$= 5 + O(g, 6 - 1) + 1$$

$$= 5 + 1 + 1$$

$$= 7$$

$$\overline{R}(gg) = C(g) + O(g, \overline{R}(g))$$

$$= 5 + O(g, 8)$$

$$= 5 + 2$$

$$= 7$$

| | | | | | | | | | | | | | | |
|--|-----------|----|----|----|----|----|----|----|----|----|----|----|-----------|-----------|
| | 0 | \$ | c | t | g | a | a | a | c | t | g | g | t | 11 |
| | 1 | a | a | a | c | t | g | g | t | \$ | c | t | g | 3 |
| | 2 | a | a | c | t | g | g | t | \$ | c | t | g | a | 4 |
| | 3 | a | c | t | g | g | t | \$ | c | t | g | a | a | 5 |
| | 4 | c | t | g | a | a | a | c | t | g | g | t | \$ | 0 |
| | 5 | c | t | g | g | t | \$ | c | t | g | a | a | a | 6 |
| | 6 | g | a | a | a | c | t | g | g | t | \$ | c | t | 2 |
| | 7 | g | g | t | \$ | c | t | g | a | a | a | c | t | 8 |
| | 8 | g | t | \$ | c | t | g | a | a | a | a | c | g | 9 |
| | 9 | t | \$ | c | t | g | a | a | a | c | t | g | g | 10 |
| | 10 | t | g | a | a | a | c | t | g | g | t | \$ | c | 1 |
| | 11 | t | g | g | t | \$ | c | t | g | a | a | a | c | 7 |

backward search

$$\underline{R}(tgg) = C(t) + O(t, \underline{R}(gg) - 1) + 1$$

$$= 8 + O(t, 7 - 1) + 1$$

$$= 8 + 2 + 1$$

$$= 11$$

| | | | | | | | | | | | | | |
|----------|-----------|---|---|---|---|---|---|---|---|---|---|----------|-----------|
| 0 | \$ | c | t | g | a | a | a | c | t | g | g | t | 11 |
|----------|-----------|---|---|---|---|---|---|---|---|---|---|----------|-----------|

| | | | | | | | | | | | | | |
|----------|----------|---|---|---|---|---|---|---|----|---|---|----------|----------|
| 1 | a | a | a | c | t | g | g | t | \$ | c | t | g | 3 |
|----------|----------|---|---|---|---|---|---|---|----|---|---|----------|----------|

| | | | | | | | | | | | | | |
|----------|----------|---|---|---|---|---|---|----|---|---|---|----------|----------|
| 2 | a | a | c | t | g | g | t | \$ | c | t | g | a | 4 |
|----------|----------|---|---|---|---|---|---|----|---|---|---|----------|----------|

| | | | | | | | | | | | | | |
|----------|----------|---|---|---|---|---|----|---|---|---|---|----------|----------|
| 3 | a | c | t | g | g | t | \$ | c | t | g | a | a | 5 |
|----------|----------|---|---|---|---|---|----|---|---|---|---|----------|----------|

| | | | | | | | | | | | | | |
|----------|----------|---|---|---|---|---|---|---|---|---|---|-----------|----------|
| 4 | c | t | g | a | a | a | c | t | g | g | t | \$ | 0 |
|----------|----------|---|---|---|---|---|---|---|---|---|---|-----------|----------|

| | | | | | | | | | | | | | |
|----------|----------|---|---|---|---|----|---|---|---|---|---|----------|----------|
| 5 | c | t | g | g | t | \$ | c | t | g | a | a | a | 6 |
|----------|----------|---|---|---|---|----|---|---|---|---|---|----------|----------|

| | | | | | | | | | | | | | |
|----------|----------|---|---|---|---|---|---|---|---|----|---|----------|----------|
| 6 | g | a | a | a | c | t | g | g | t | \$ | c | t | 2 |
|----------|----------|---|---|---|---|---|---|---|---|----|---|----------|----------|

| | | | | | | | | | | | | | |
|----------|----------|---|---|----|---|---|---|---|---|---|---|----------|----------|
| 7 | g | g | t | \$ | c | t | g | a | a | a | c | t | 8 |
|----------|----------|---|---|----|---|---|---|---|---|---|---|----------|----------|

| | | | | | | | | | | | | | |
|----------|----------|---|----|---|---|---|---|---|---|---|---|----------|----------|
| 8 | g | t | \$ | c | t | g | a | a | a | c | t | g | 9 |
|----------|----------|---|----|---|---|---|---|---|---|---|---|----------|----------|

| | | | | | | | | | | | | | |
|----------|----------|----|---|---|---|---|---|---|---|---|---|----------|-----------|
| 9 | t | \$ | c | t | g | a | a | a | c | t | g | g | 10 |
|----------|----------|----|---|---|---|---|---|---|---|---|---|----------|-----------|

| | | | | | | | | | | | | | |
|-----------|----------|---|---|---|---|---|---|---|---|---|----|----------|----------|
| 10 | t | g | a | a | a | c | t | g | g | t | \$ | c | 1 |
|-----------|----------|---|---|---|---|---|---|---|---|---|----|----------|----------|

| | | | | | | | | | | | | | |
|-----------|----------|---|---|---|----|---|---|---|---|---|---|----------|----------|
| 11 | t | g | g | t | \$ | c | t | g | a | a | a | c | 7 |
|-----------|----------|---|---|---|----|---|---|---|---|---|---|----------|----------|

backward search

| | | | | | | | | | | | | | | |
|---|-----------|----|----|----|----|----|----|----|----|----|----|----|-----------|-----------|
| $\underline{R}(ctgg) = C(c) + O(c, \underline{R}(tgg) - 1) + 1$ | 0 | \$ | c | t | g | a | a | a | c | t | g | g | t | 11 |
| $= 3 + O(c, 11 - 1) + 1$ | 1 | a | a | a | c | t | g | g | t | \$ | c | t | g | 3 |
| $= 3 + 1 + 1$ | 2 | a | a | c | t | g | g | t | \$ | c | t | g | a | 4 |
| $= 5$ | 3 | a | c | t | g | g | t | \$ | c | t | g | a | a | 5 |
| $\bar{R}(ctgg) = C(c) + O(c, \bar{R}(tgg))$ | 4 | c | t | g | a | a | a | c | t | g | g | t | \$ | 0 |
| $= 3 + O(c, 11)$ | 5 | c | t | g | g | t | \$ | c | t | g | a | a | a | 6 |
| $= 3 + 2$ | 6 | g | a | a | a | c | t | g | g | t | \$ | c | t | 2 |
| $= 5$ | 7 | g | g | t | \$ | c | t | g | a | a | a | c | t | 8 |
| | 8 | g | t | \$ | c | t | g | a | a | a | c | t | g | 9 |
| | 9 | t | \$ | c | t | g | a | a | a | c | t | g | g | 10 |
| | 10 | t | g | a | a | a | c | t | g | g | t | \$ | c | 1 |
| | 11 | t | g | g | t | \$ | c | t | g | a | a | a | c | 7 |

backward search

$$\begin{aligned}
 \underline{R}(ttgg) &= C(t) + O(t, \underline{R}(tgg) - 1) + 1 \\
 &= 8 + O(t, 11 - 1) + 1 \\
 &= 8 + 3 + 1 \\
 &= 12
 \end{aligned}$$

| | |
|--|---|
| $\underline{R}(ttgg) = C(t) + O(t, \underline{R}(tgg) - 1) + 1$ $= 8 + O(t, 11 - 1) + 1$ $= 8 + 3 + 1$ $= 12$ | 0 \$ c t g a a a c t g g t g g t 11 1 a a a c t g g t \$ c t g t g 3 2 a a c t g g t \$ c t g g a a 4 |
|--|---|

$$\begin{aligned}
 \overline{R}(ttgg) &= C(t) + O(t, \overline{R}(tgg)) \\
 &= 8 + O(t, 11) \\
 &= 8 + 2 \\
 &= 11
 \end{aligned}$$

| | |
|--|--|
| $\overline{R}(ttgg) = C(t) + O(t, \overline{R}(tgg))$ $= 8 + O(t, 11)$ $= 8 + 2$ $= 11$ | 3 a c t g g t \$ c t g g a a 5 4 c t g a a a c t g g t \$ 0 5 c t g g t \$ c t g a a a a 6 6 g a a a c t g g t \$ c t 2 |
|--|--|

$$\begin{aligned}
 \underline{R}(aW) \leq \overline{R}(aW) : \text{配列 } aW \text{ が存在する条件}
 \end{aligned}$$

| | |
|---|---|
| $\underline{R}(aW) \leq \overline{R}(aW) : \text{配列 } aW \text{ が存在する条件}$ | 7 g g t \$ c t g a a a a c t 8 8 g t \$ c t g a a a a c t g 9 9 t \$ c t g a a a a c t g g 10 10 t g a a a c t g g t \$ c 1 11 t g g t \$ c t g a a a a c 7 |
|---|---|

Backward Search

$$\underline{R}(ct) = C(c) + O(c, \underline{R}(t)-1) + 1$$

$$= 3 + O(c, 9-1) + 1$$

$$= 3 + 0 + 1$$

$$= 4$$

$$\overline{R}(ct) = C(c) + O(c, \overline{R}(t))$$

$$= 3 + O(c, 11)$$

$$= 3 + 2$$

$$= 5$$

| | | | | | | | | | | | | | |
|-----------|-----------|----|----|----|----|----|----|----|----|----|----|-----------|-----------|
| 0 | \$ | c | t | g | a | a | a | c | t | g | g | t | 11 |
| 1 | a | a | a | c | t | g | g | t | \$ | c | t | g | 3 |
| 2 | a | a | c | t | g | g | t | \$ | c | t | g | a | 4 |
| 3 | a | c | t | g | g | t | \$ | c | t | g | a | a | 5 |
| 4 | c | t | g | a | a | a | c | t | g | g | t | \$ | 0 |
| 5 | c | t | g | g | t | \$ | c | t | g | a | a | a | 6 |
| 6 | g | a | a | a | c | t | g | g | t | \$ | c | t | 2 |
| 7 | g | g | t | \$ | c | t | g | a | a | a | c | t | 8 |
| 8 | g | t | \$ | c | t | g | a | a | a | c | t | g | 9 |
| 9 | t | \$ | c | t | g | a | a | a | c | t | g | g | 10 |
| 10 | t | g | a | a | a | c | t | g | g | t | \$ | c | 1 |
| 11 | t | g | g | t | \$ | c | t | g | a | a | a | c | 7 |

Backward Search

$$\underline{R}(act) = C(a) + O(a, \underline{R}(ct) - 1) + 1$$

$$= 0 + O(a, 4 - 1) + 1$$

$$= 0 + 2 + 1$$

$$= 3$$

0 **\$** c t g a a a c t g g t \$ c t g g t **t** **11**

1 **a** a a c t g g t \$ c t g **g** **3**

2 **a** a c t g g t \$ c t g **a** **4**

3 **a** c t g g t \$ c t g a **a** **5**

4 **c** t g a a a c t g g t **\$** **0**

5 **c** t g g t \$ c t g a a **a** **6**

6 **g** a a a a c t g g t \$ c t **t** **2**

7 **g** g t \$ c t g a a a c **t** **8**

8 **g** t \$ c t g a a a c t **g** **9**

9 **t** \$ c t g a a a c t g **g** **10**

10 **t** g a a a c t g g t \$ **c** **1**

11 **t** g g t \$ c t g a a a **c** **7**

$$\overline{R}(act) = C(a) + O(a, \overline{R}(ct))$$

$$= 0 + O(a, 5)$$

$$= 0 + 3$$

$$= 3$$

第2回 予定

Integrative Genomics Viewer(IGV)による可視化

- samtoolsでファイル変換
 - 1) sam→bam変換
 - 2) bamファイルを染色体順に並べ替え
 - 3) indexファイルの作成
- IGVへアップロード、表示