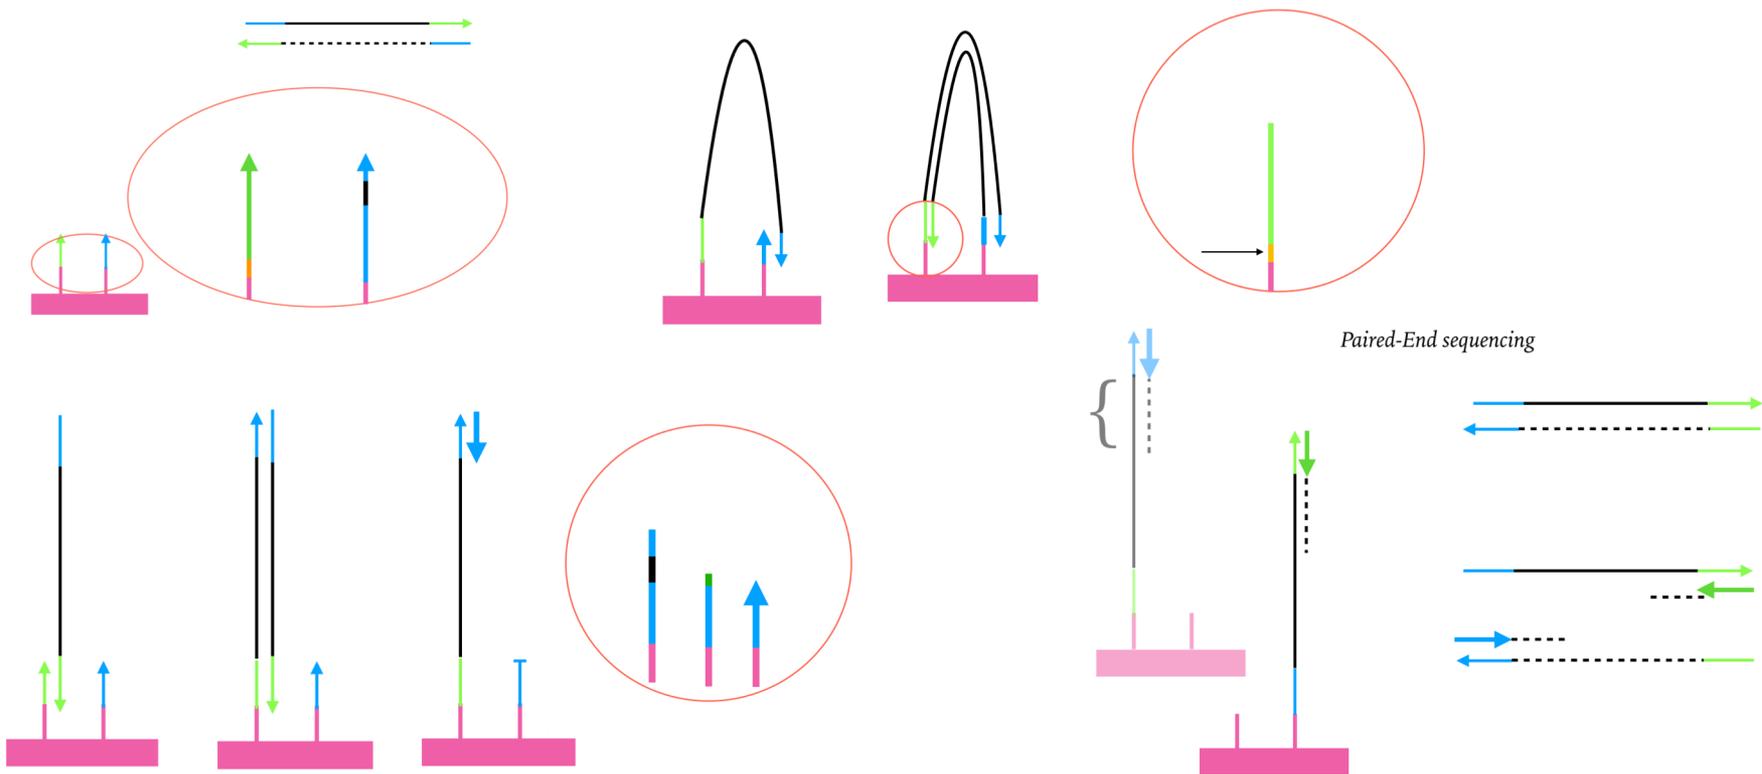


# Картирование

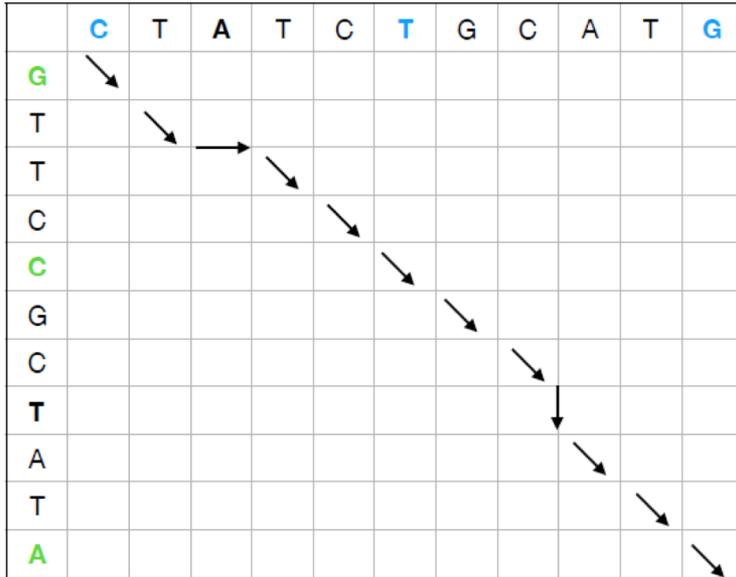
Герасимов Евгений  
jalgard@gmail.com

# Парные чтения (Illumina)

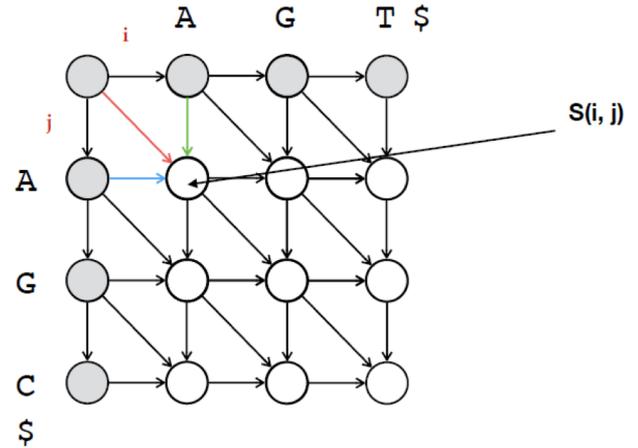


# Выравнивания

Y P S Y L H A D D S A V V Q A A S A  
 C T A T C C G T C C T A T C T G C A T G A C - - T C C G C C G T C G T T C A A G C G G C T T C G G C G G C  
 C T A T C C G T C G T - T C C G C T A T A C G G A A G C C G A T C C G - - G T C G T - - - - G A G G C - T C G C C G T C  
 Y P S F R Y T E A D P V V R L A V



$$S(i, j) = \max \begin{cases} S_{(i-1, j)} + M(i, j) \\ S_{(i, j-1)} + G(i) \\ S_{(i-1, j-1)} + G(j) \end{cases} \quad \begin{matrix} G & = & -1 \\ M(i == j) & = & +2 \\ M(i \neq j) & = & -1 \end{matrix}$$



# Задача картирования

## Референсный геном

AGTAGTTTTCTCAAGTTATTATTTTTGTAAGTGTATGTTAATATCTCTAGCAAATTTAAGAAGGAATTCC  
ATTTAATTСТАААТATGCAAAAATGAAATTTTTTACAAACATAGAATAATATAAATTCATAAACCTTAAA  
AAACAAATTCATTTGATATTTGATAAATAAATTAAGTAAGGCAAATTTAATCTTGATTCGTAAGGTATGT  
CATATTTGTGCGTAGTСТААТСССААТСССААТATTTGTAAGCGGTTTCACTAAATATGTTATTTTTTTA  
TTTGTATATAATATGGCATTATGAAAATGTAAACTTATCTTTTATTATAAATTTAAAAACAAATTCCTTCT  
ATTTCAAAATСССААААСААСТTAAAATTTGTAААТATGTTTTACSTATCCAAATTGTTATTTTCATTT  
GТАСТTGTACAAACTTTTTTAACAAATTTAAAAAACAAATTCCTTTCTTTCCACTTTAGAAATTTAAAAG  
AAATTTAAAACGCACСAААТАААТАААТATAAATCTTTTTAAATGTTTAGATAGTTTTATCCAAATTGTTA  
TTTTTGTAATAAGCATAAATCCTTTAGCCTTAAAAAATCTAATAATAAATTAAACACCCCTGATGAAGA  
...

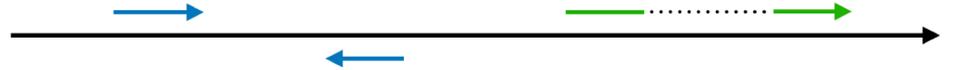
**AAATCCTTTAGCCTT**

**AGGGGTGTTTAATTT**



# Терминология

- Reference
- Mapping / alignment
- Forward / reverse strand
- Paired-end / Mate-pair
- Primary / secondary alignment
- Chimeric / junction / split alignment
- Unique / multimap / unmapped
- Concordant / discordant
- Insert size



# Особенности задачи

- Геном (текст) достаточно большой ( ~3Gb геном человека )
- Геном известен заранее и не изменяется
- Чтений (паттернов) очень много, но они все короткие
- Чтения очень похожи (часто идентичны) геному
- Каждое чтение можно обрабатывать независимо



- Алгоритм может требовать много ресурсов (оперативной памяти)
- Геном можно подготовить заранее
- Алгоритм может требовать много ресурсов (процессорного времени)
- Можно использовать *алгоритмы поиска точного совпадения*, а не выравнивания
- Задача будет хорошо параллелироваться

# Препроцессинг генома



# Полезные свойства BWT

1. Сжатие (без потери)

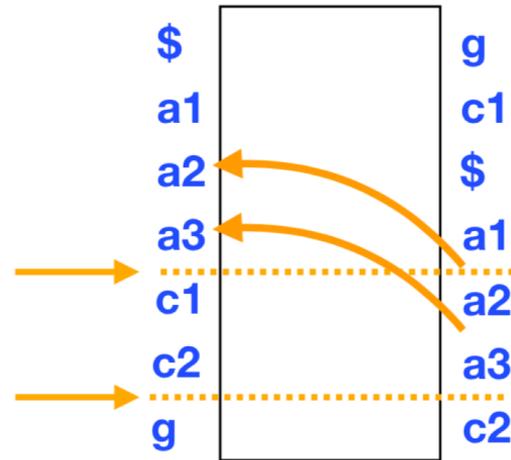
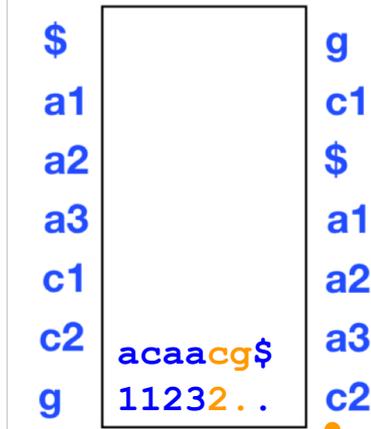
асаасg\$

gc\$3ас\_

2. Быстрый поиск **bwt**

g  
c1  
\$  
a1  
a2  
a3  
c2

сортировка



собственно  
ПОИСК

# Дальнейшее развитие темы: FM-index

$$LF(i) = C[L[i]] + \text{Occ}(L[i], i)$$

**bwt**

	<b>C:</b>		<b>Occ:</b>						
			1	2	3	4	5	6	7
<b>g</b>									
<b>c1</b>	\$	0	\$	0	0	1	1	1	1
<b>\$</b>	a	1	a	0	0	0	1	2	3
<b>a1</b>	c	4	c	0	1	1	1	1	2
<b>a2</b>	g	6	g	1	1	1	1	1	1

**a3**

**c2**

$$\begin{aligned} LF(3) &= C[L[3]] + \text{Occ}(L[3], 3) = \\ &= C['\$'] + \text{Occ}('$', 3) = 0 + 1 = 1 \end{aligned}$$

$$\begin{aligned} LF(2) &= C[L[2]] + \text{Occ}(L[2], 2) = \\ &= C['c'] + \text{Occ}('c', 2) = 4 + 1 = 5 \end{aligned}$$

\$acaacg  
aacg\$ac  
acaacg\$  
acg\$aca  
caacg\$a  
cg\$acaa  
g\$acaac

# Реальные инструменты, использующие BWT / FM-index

## bowtie / **bowtie2**:

- использует FM-index для поиска seeds, seed может иметь 0, 1 или 2 замены
- каждый найденный 'seed'-локус продляется с использованием Smith-Waterman
- имеется режим end-to-end ('глобального') и local ('локального' выравнивания) работы с ридом
- есть некоторые технические ограничения на количество seeds, которое находится для рида

## **BWA**:

- использует FM-index, чтобы найти области максимального точного совпадения (mem)
- использует Smith-Waterman для продления выравнивания
- может быть использован для ридов очень большой длины (PacBio)
- каждый рид может иметь несколько локальных выравниваний (разные части длинного рида)

# Преимущества и недостатки



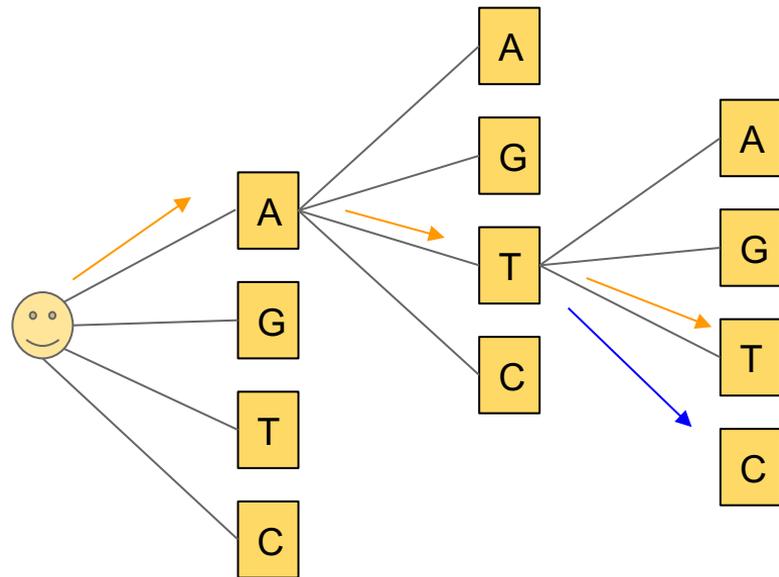
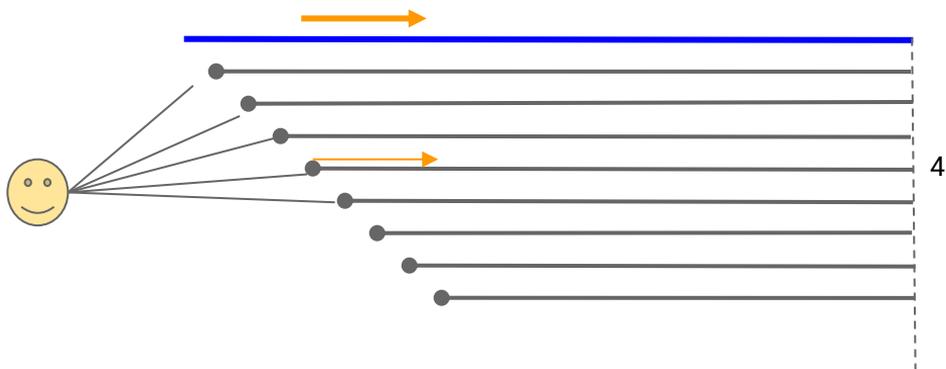
- геном может храниться в сжатом виде
- найти seeds / mems довольно “просто”
- хорошее сочетание скорости и качества выравнивания (прохождения пространства поиска)
- лучшее соотношение скорости к размеру индекса в памяти
- отлично адаптируются к длинным ридам



- не эффективно искать seed, если есть несовпадения (mismatches), с коротким seed сильно теряется скорость работы
- время поиска seed по-прежнему  $\sim \log(\text{геном})$
- нет четких оснований, по которым выбирается оптимальная длина seed

# Другие подходы: суффиксы и префиксы

Суффиксное дерево



# Другие подходы: хэширование

Хэш-таблицы

AAATCCTTTAGCCTT

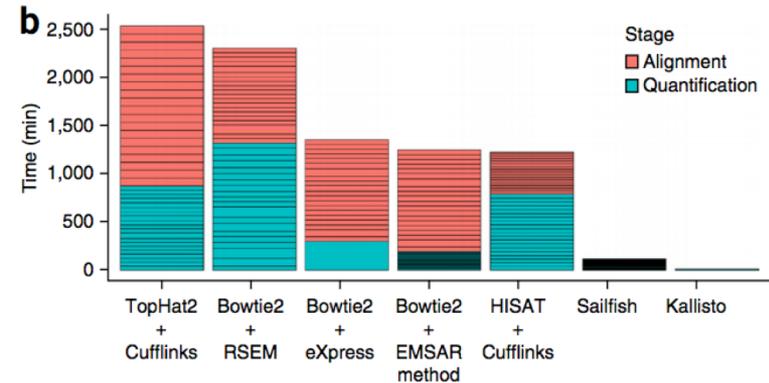
$hash(kmer) = index$

AAAT	24, 38
TTAA	...
CCTT	...

GTACTTGTACAAACTTTTTTAA  
CAAATTTAAAAACAATTC  
TTTCTTTCCACTTTAGAATTTA  
AAAG...

“Alignment-free” методы:

- используют частоты kmer-ов для кластеризации ридов между заданным набором образцов
- быстры (очень)
- используются в метагеномике и транскриптомике



# Некоторые замечания

По разным данным FM-index может превосходить по скорости отдельные хэш-картировщики = многое зависит от конкретной реализации

# Сравнение особенностей алгоритмов



- хэш-основанные алгоритмы - самые быстрые и самые (или одни из самых) эффективных в плане требований по памяти
- алгоритмы на суффиксных деревьях тоже очень быстрые (сравнимо с хэш), но позволяют получать гораздо более оптимальное выравнивание (как?)



- хэш-основанные подходы плохо работают с ридами, если в них есть ошибки и замены, еще хуже - индели
- хэш-основанные алгоритмы, строго говоря, не дают выравнивания
- алгоритмы на суффиксных деревьях очень требовательны к памяти

# Слишком короткие чтения

В коротком тексте слишком мало информации

Технические проблемы:

- недостаточно kmer-ов можно извлекать из рида, недостаточное количество хороших seeds можно подобрать
- выравнивание всегда будет иметь невысокий score, легче найти альтернативное выравнивание с таким же score

Короткие чтения, как правило, картируются в несколько мест (не уникально)

# Профиль покрытия



# О чем говорит профиль покрытия?

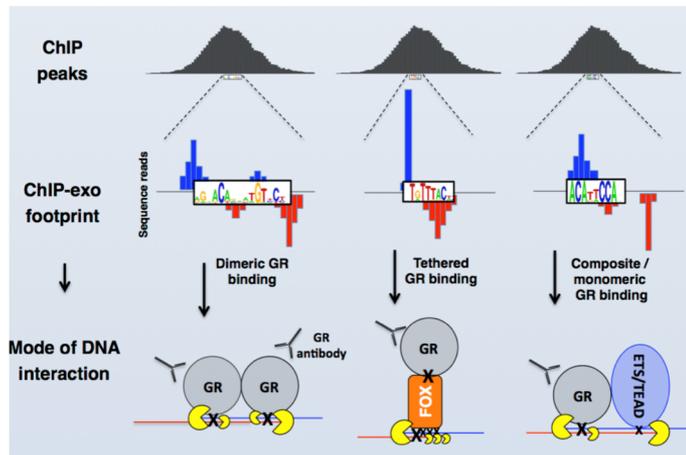
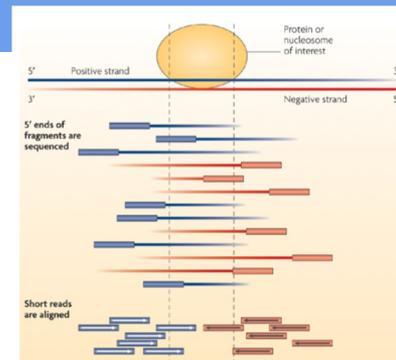
- Структурные вариации разного масштаба

SNP  
Indels  
CNV  
Fusion

- Экспрессия генов

- Взаимодействия молекул

ChIP-seq  
HiC  
Mnase-seq  
CAGE



# SNP-calling

SNP нельзя найти, если разрешить только картирование с полным совпадением!

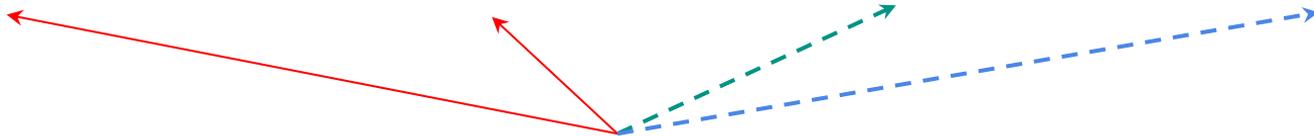
Некоторые конкретные следствия:

- SNP-calling будет зависеть от выбора картировщика
- SNP-calling будет зависеть от настроек картировщика
- SNP-caller должен уметь фильтровать потенциальные баги картирования
- SNP не может находиться в seed / kmer
- Сближенные SNP сложнее “ловить”

# Уникальность картирования

*разные программы по-разному подходят к вопросу об уникальности картирования*

AAATCCTTTAGCCTT — AAATCCTTTAGCCTT — AAATCCGTTAGCCTT — AAATCCTTAGCCTT



AAATCCTTTAGCCTT

специальные тэги в sam-файле:

bwa:

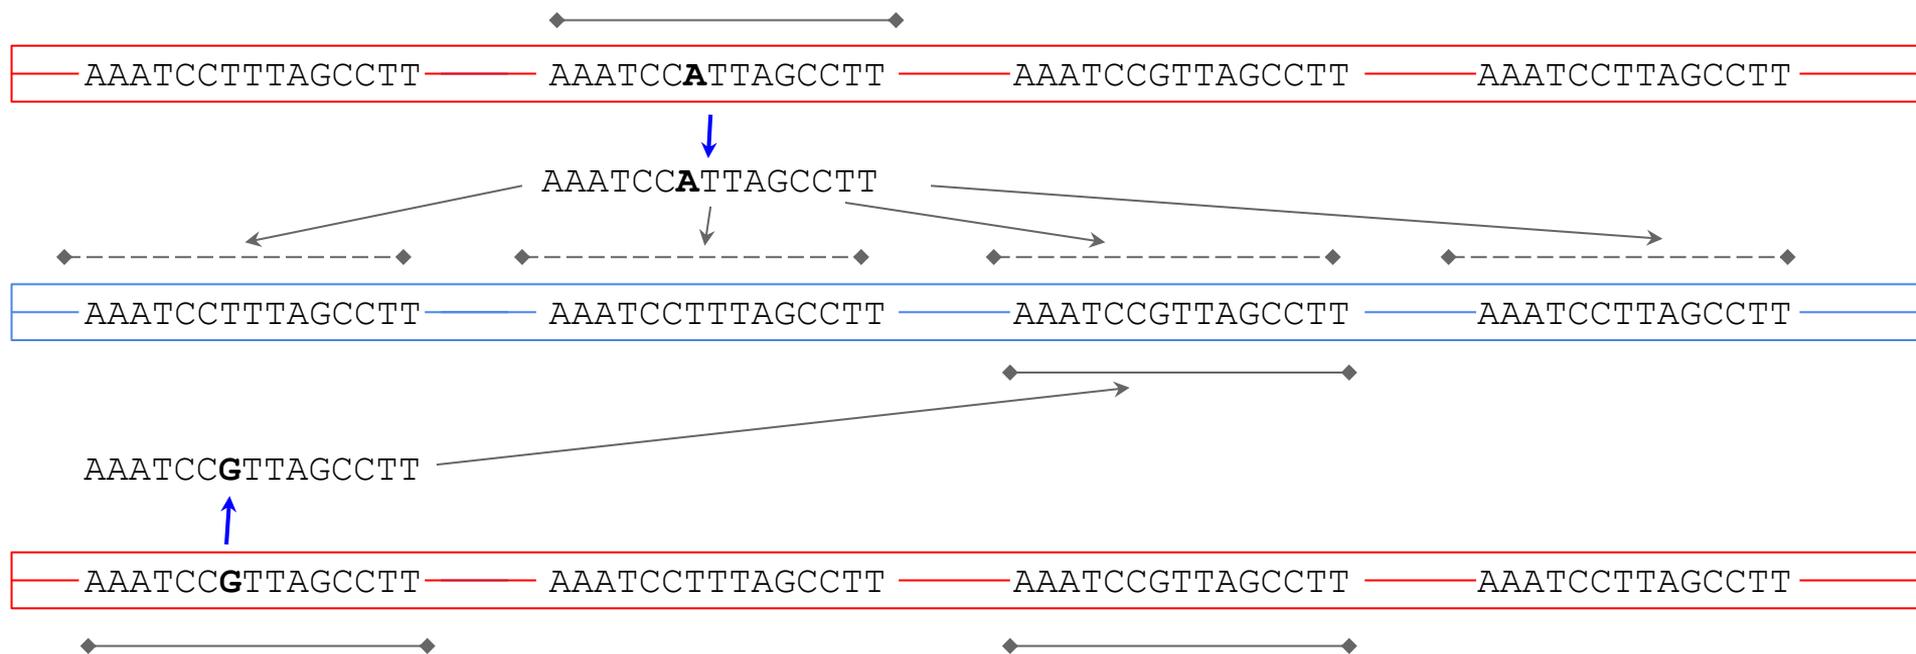
XT:A:R

hcut2:

YQ:i

Нельзя просто смотреть на  
MAPQ!

# Эффект “притяжения” к референсу



# Сложности с интронами

split alignment и chimeric alignment

AAACAAATTCATTTGATATTTGTATAAATAAATTAAGTAAGGTCAAATTTAATCTTGATTCGTAAGGTATGT  
ATTTGATATTT-----GTCAAА (ПРАВИЛЬНО)  
ATTTGATATTTGT-----CAAА