# Поиск подстрок

Николай Вяхxи
vyahhi@bioinformaticsinstitute.ru

Computer Science Club
Санкт-Петербург, 2013

Институт Биоинформатики

# Формат обучения

12 лекций по воскресеньям

Квизы для самопроверки

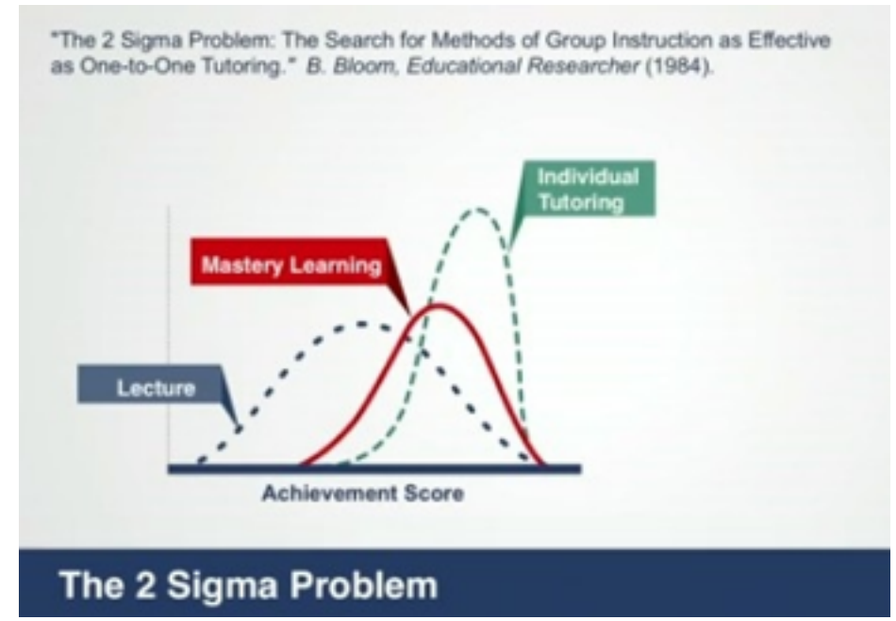


Домашние задания и вопросы онлайн

http://rosalind.info/classes/enroll/ff45302de4/

# Ответы на квиз

1. abcdabscabcdabia
   0000120012345601

2. $3*5^3 + 2*5^2 + 1*5^1 + 2*5^0 = 432$

3. a b c d i s
   12 13 10 11 14 6

4. a b c d a b s c a b c d a b i a
   15 ..... 15 3

5. 20

# В прошлый раз

Наивный алгоритм

Кнут – Моррис – Пратт

Рабин – Карп

Бойер – Мурр

Неточный поиск с заменами

# Сегодня

DNA Sequencing

Бор

Ахо – Корасик

# Микрочипы

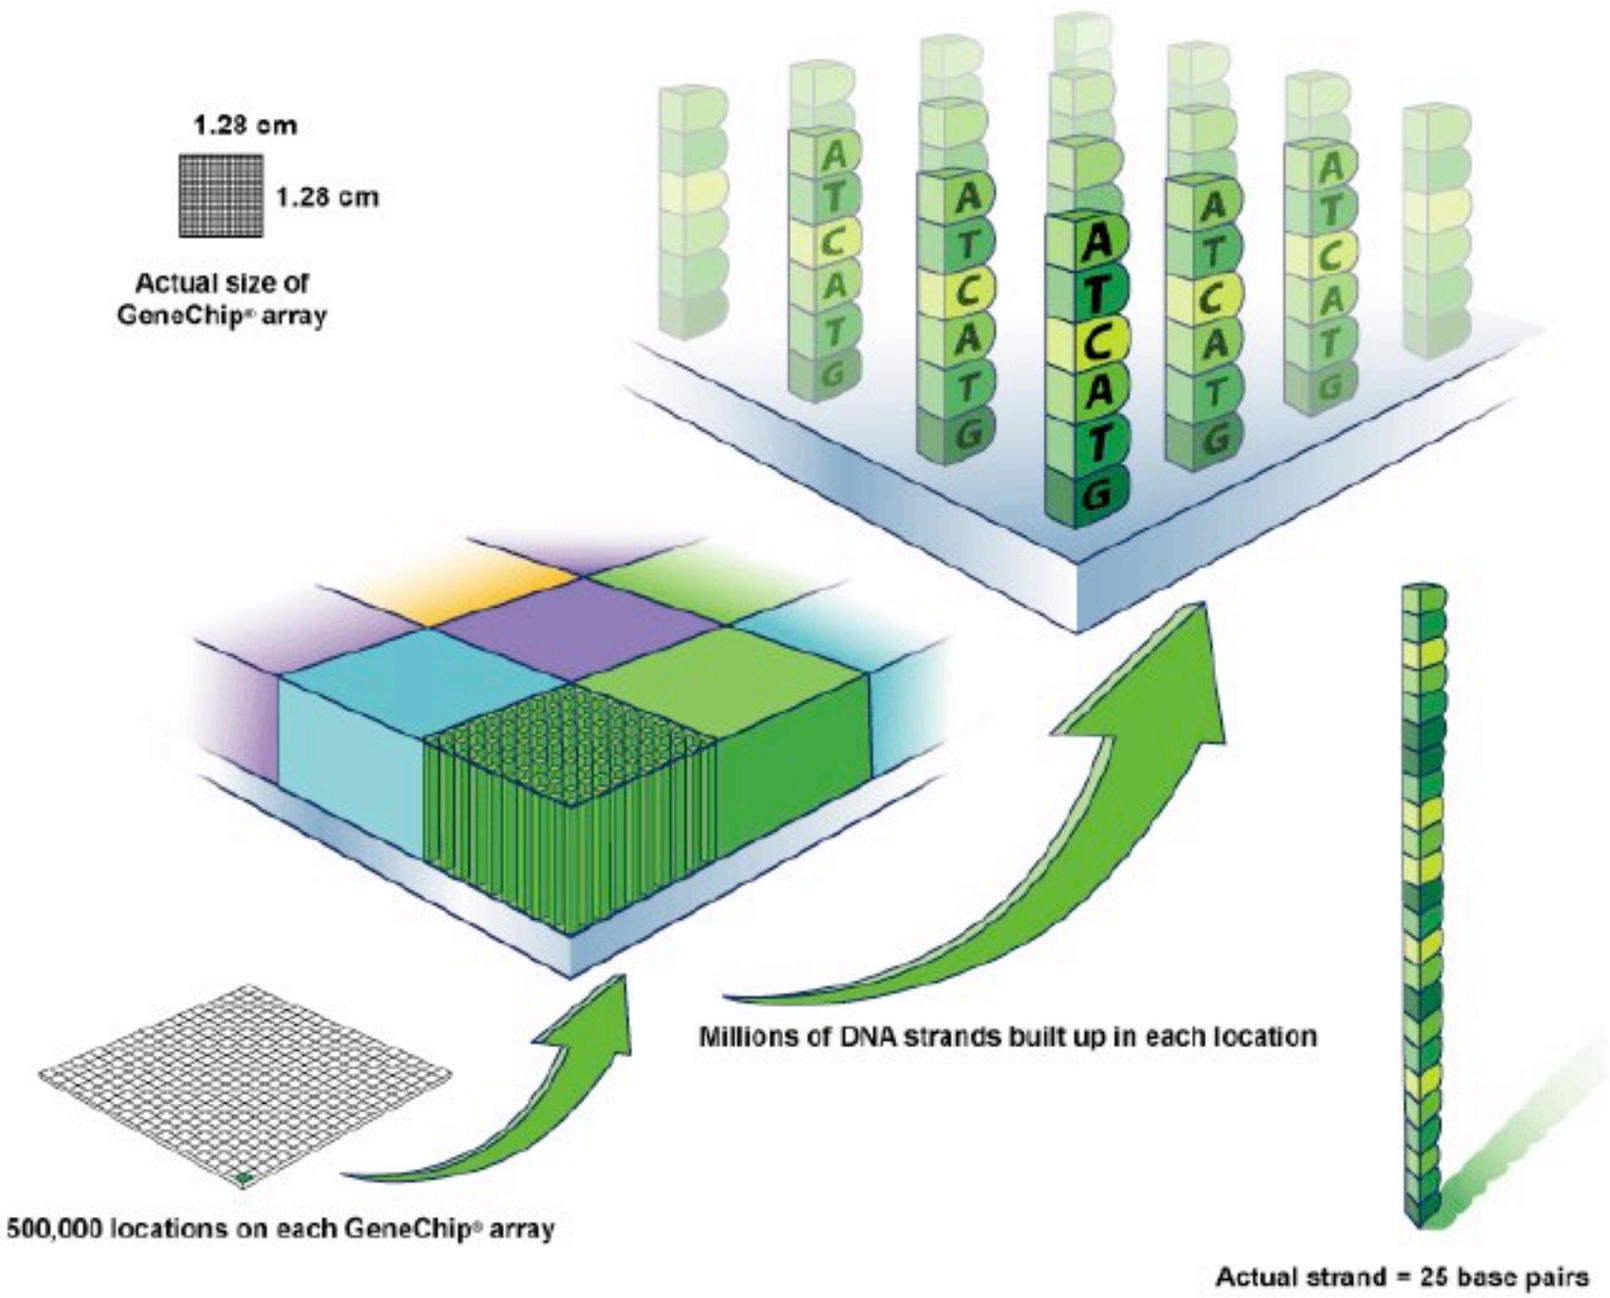
1.28 cm
1.28 cm
Actual size of GeneChip® array
Millions of DNA strands built up in each location
500,000 locations on each GeneChip® array
Actual strand = 25 base pairs

# Микрочипы

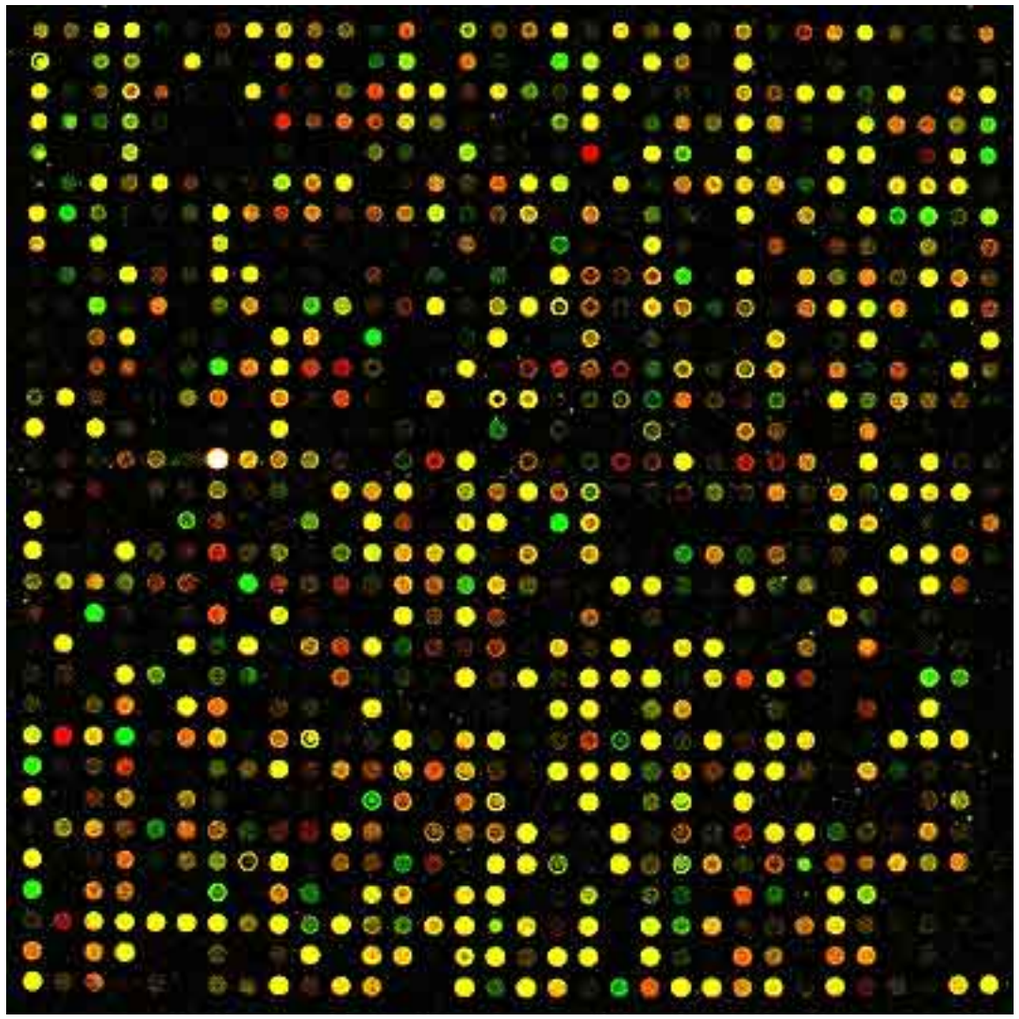

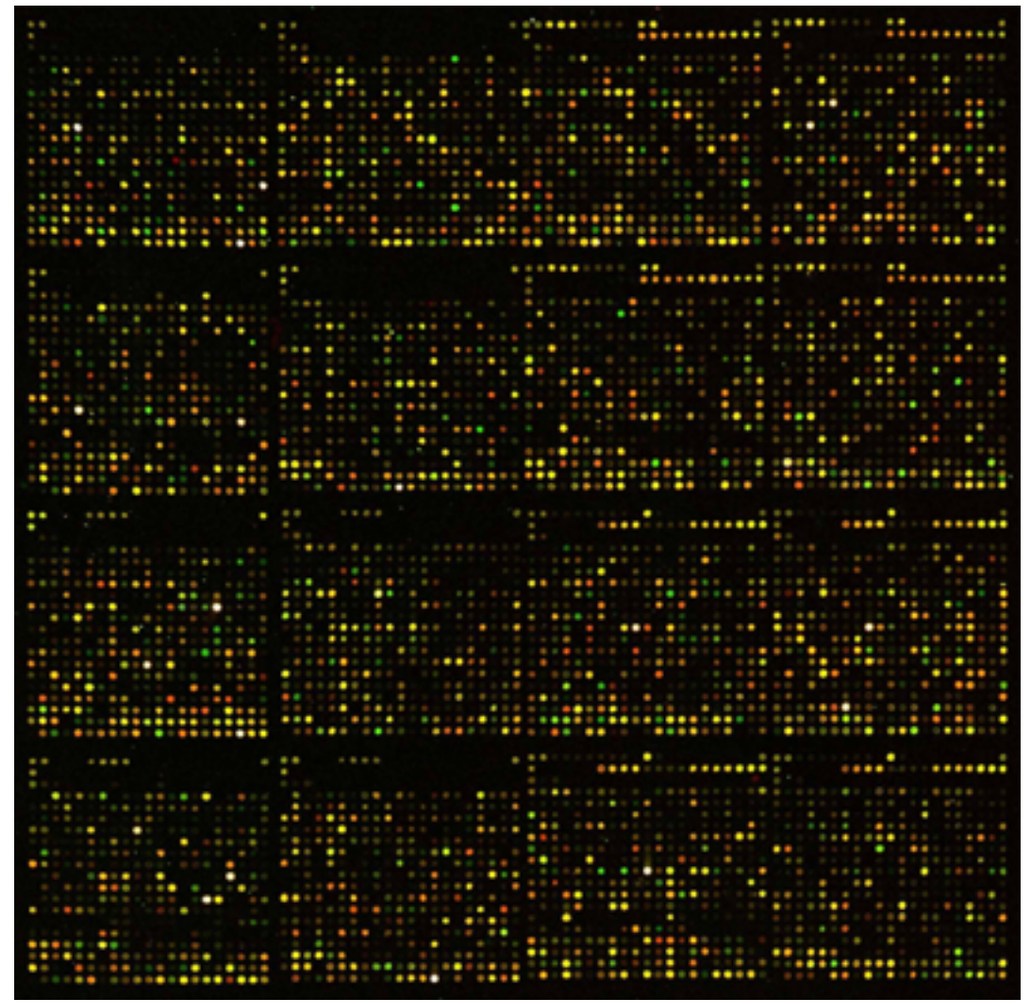

# Краткая история

Конец **1970**-х: Уолтер Гилберт и Фредерик Сэнгер развивают независимые методы секвенирования.

**1980**: Они получают Нобелевскую премию по химии.

Их методы выявления последовательности слишком дороги для больших геномов.

# Краткая история

**1990**: Общественный проект «Человеческий геном», возглавляемый Фрэнсисом Коллинзом, задаётся целью расшифровать человеческий геном.

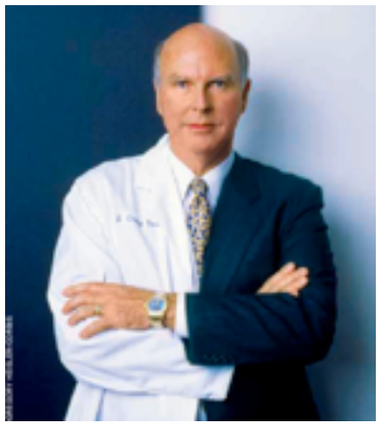

**1997**: Крейг Вентер создаёт частную компанию «Celera Genomics» с той же целью.

# Краткая история

**2000**: Черновой вариант человеческого генома одновременно завершён (общественным) проектом «Человеческий геном» и (частной) компанией Celera Genomics.

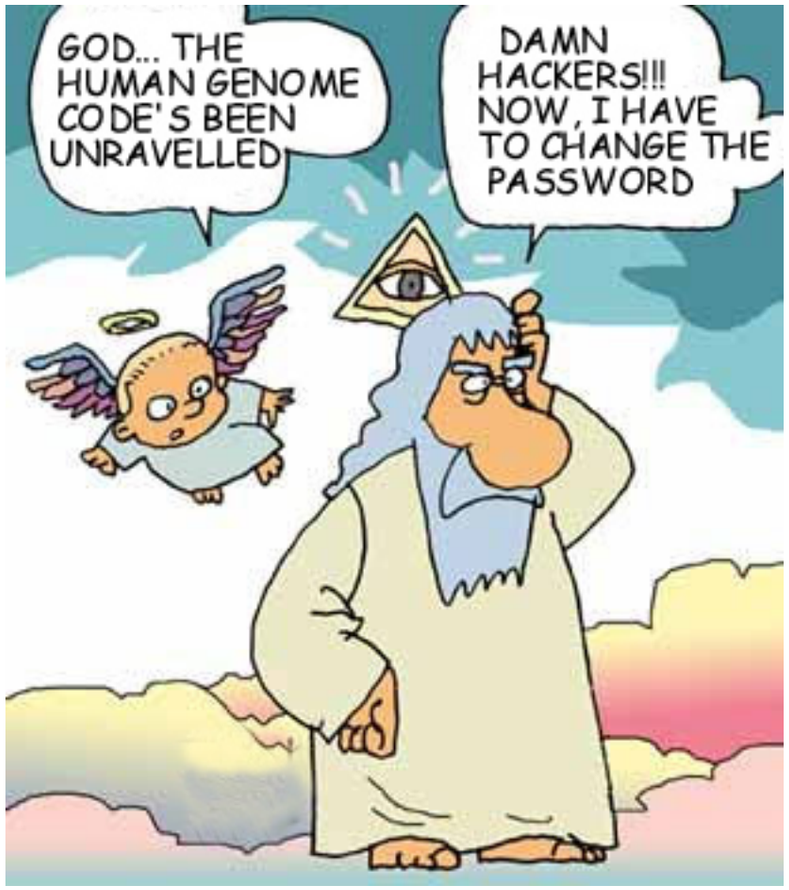

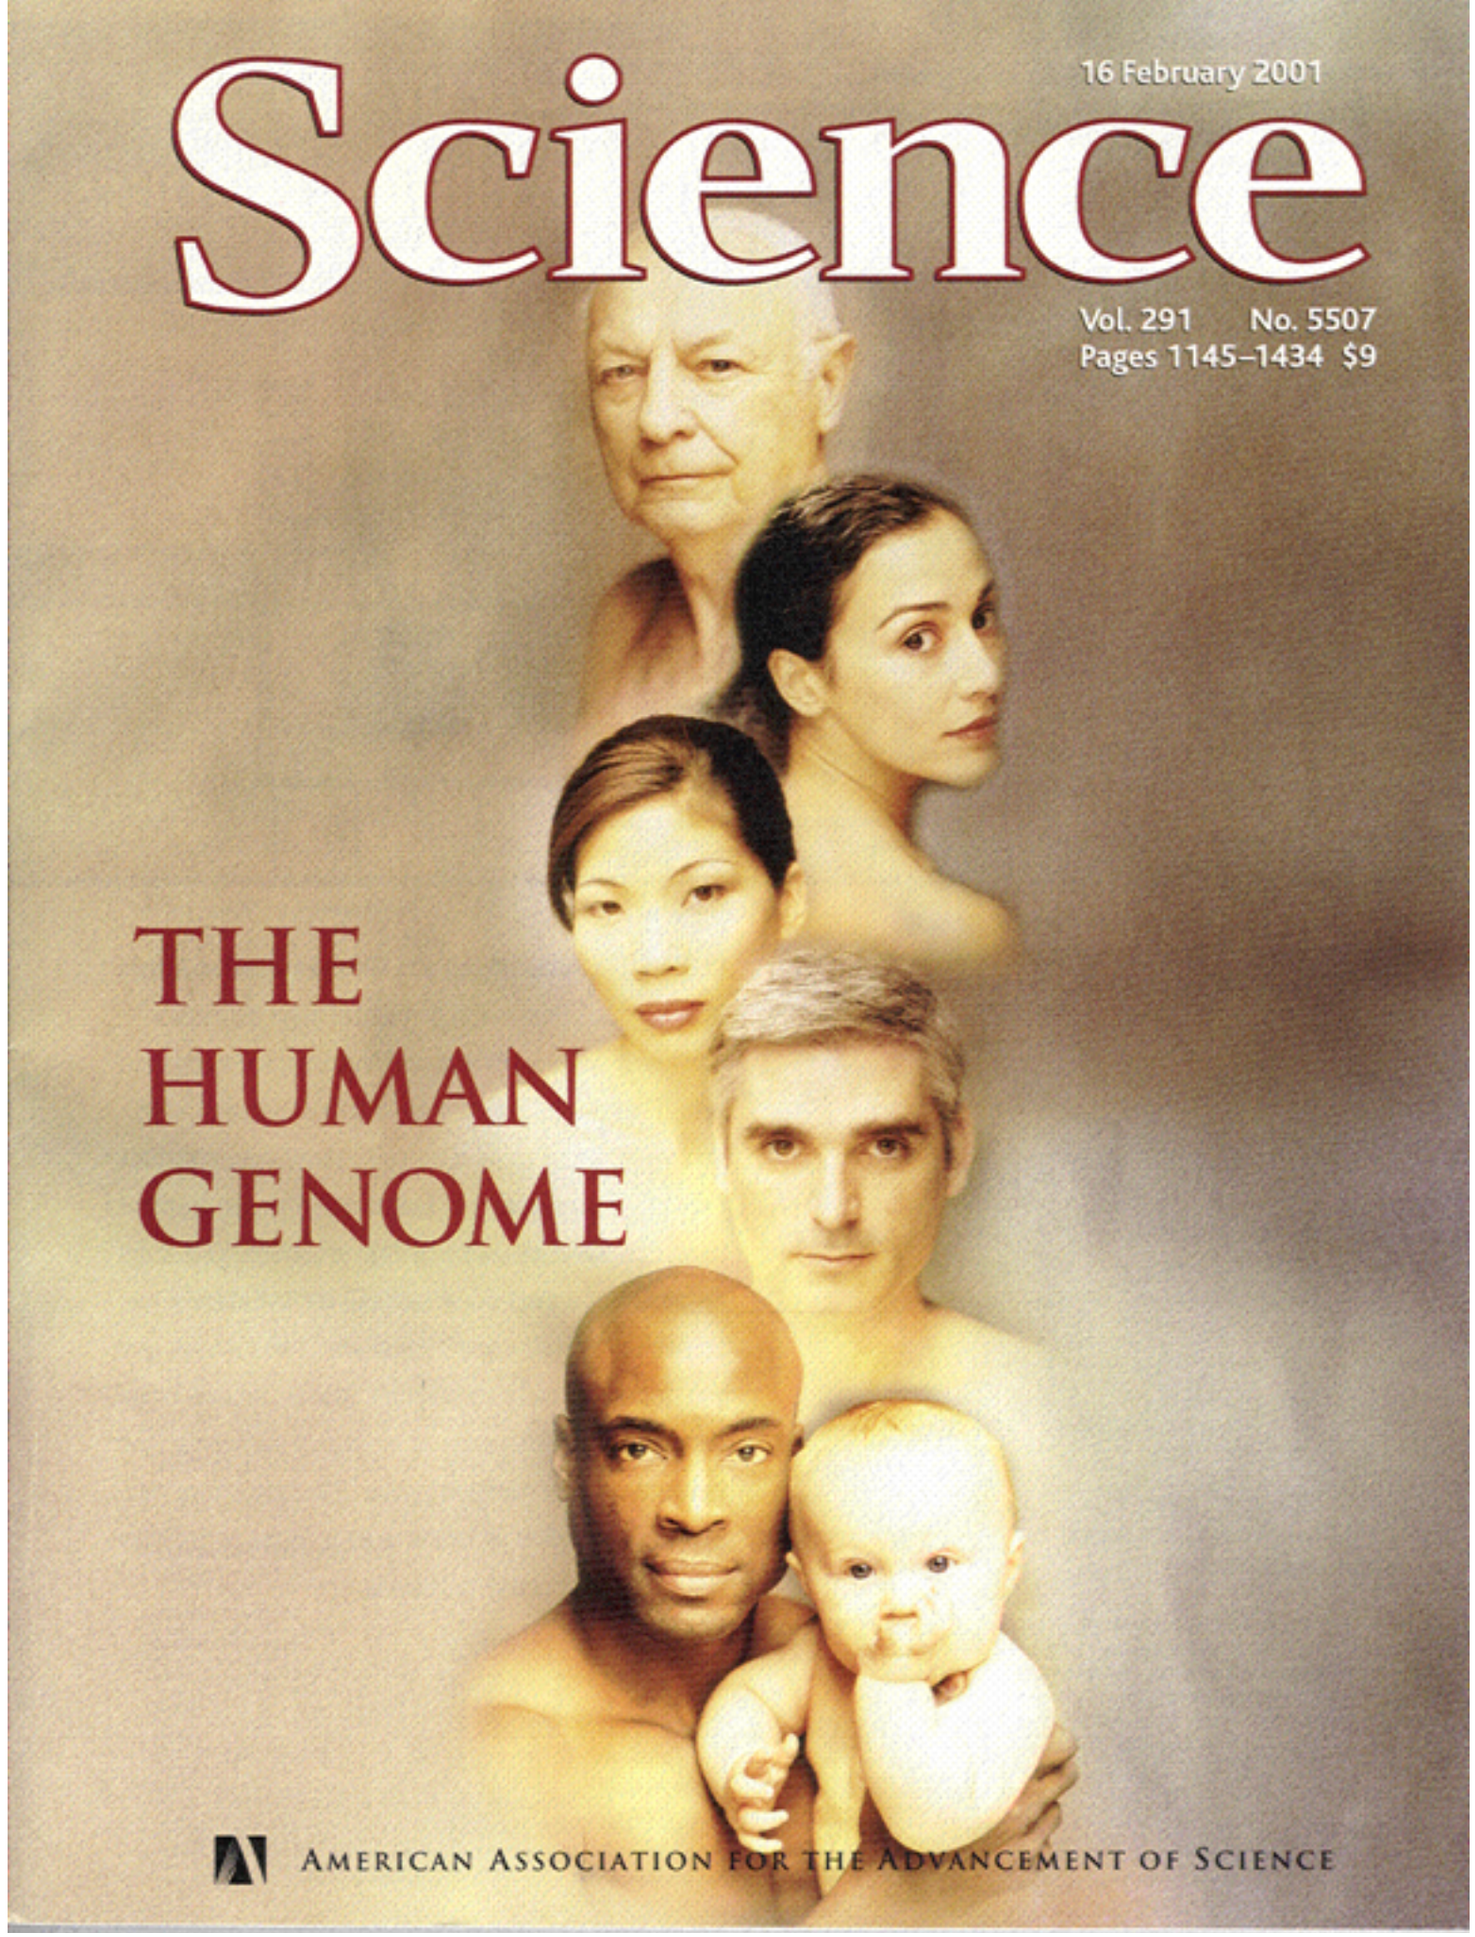
Science
16 February 2001
Vol. 291 No. 5507
Pages 1145–1434 $9
THE HUMAN GENOME
AMERICAN ASSOCIATION FOR THE ADVANCEMENT OF SCIENCE

# Эволюция технологий

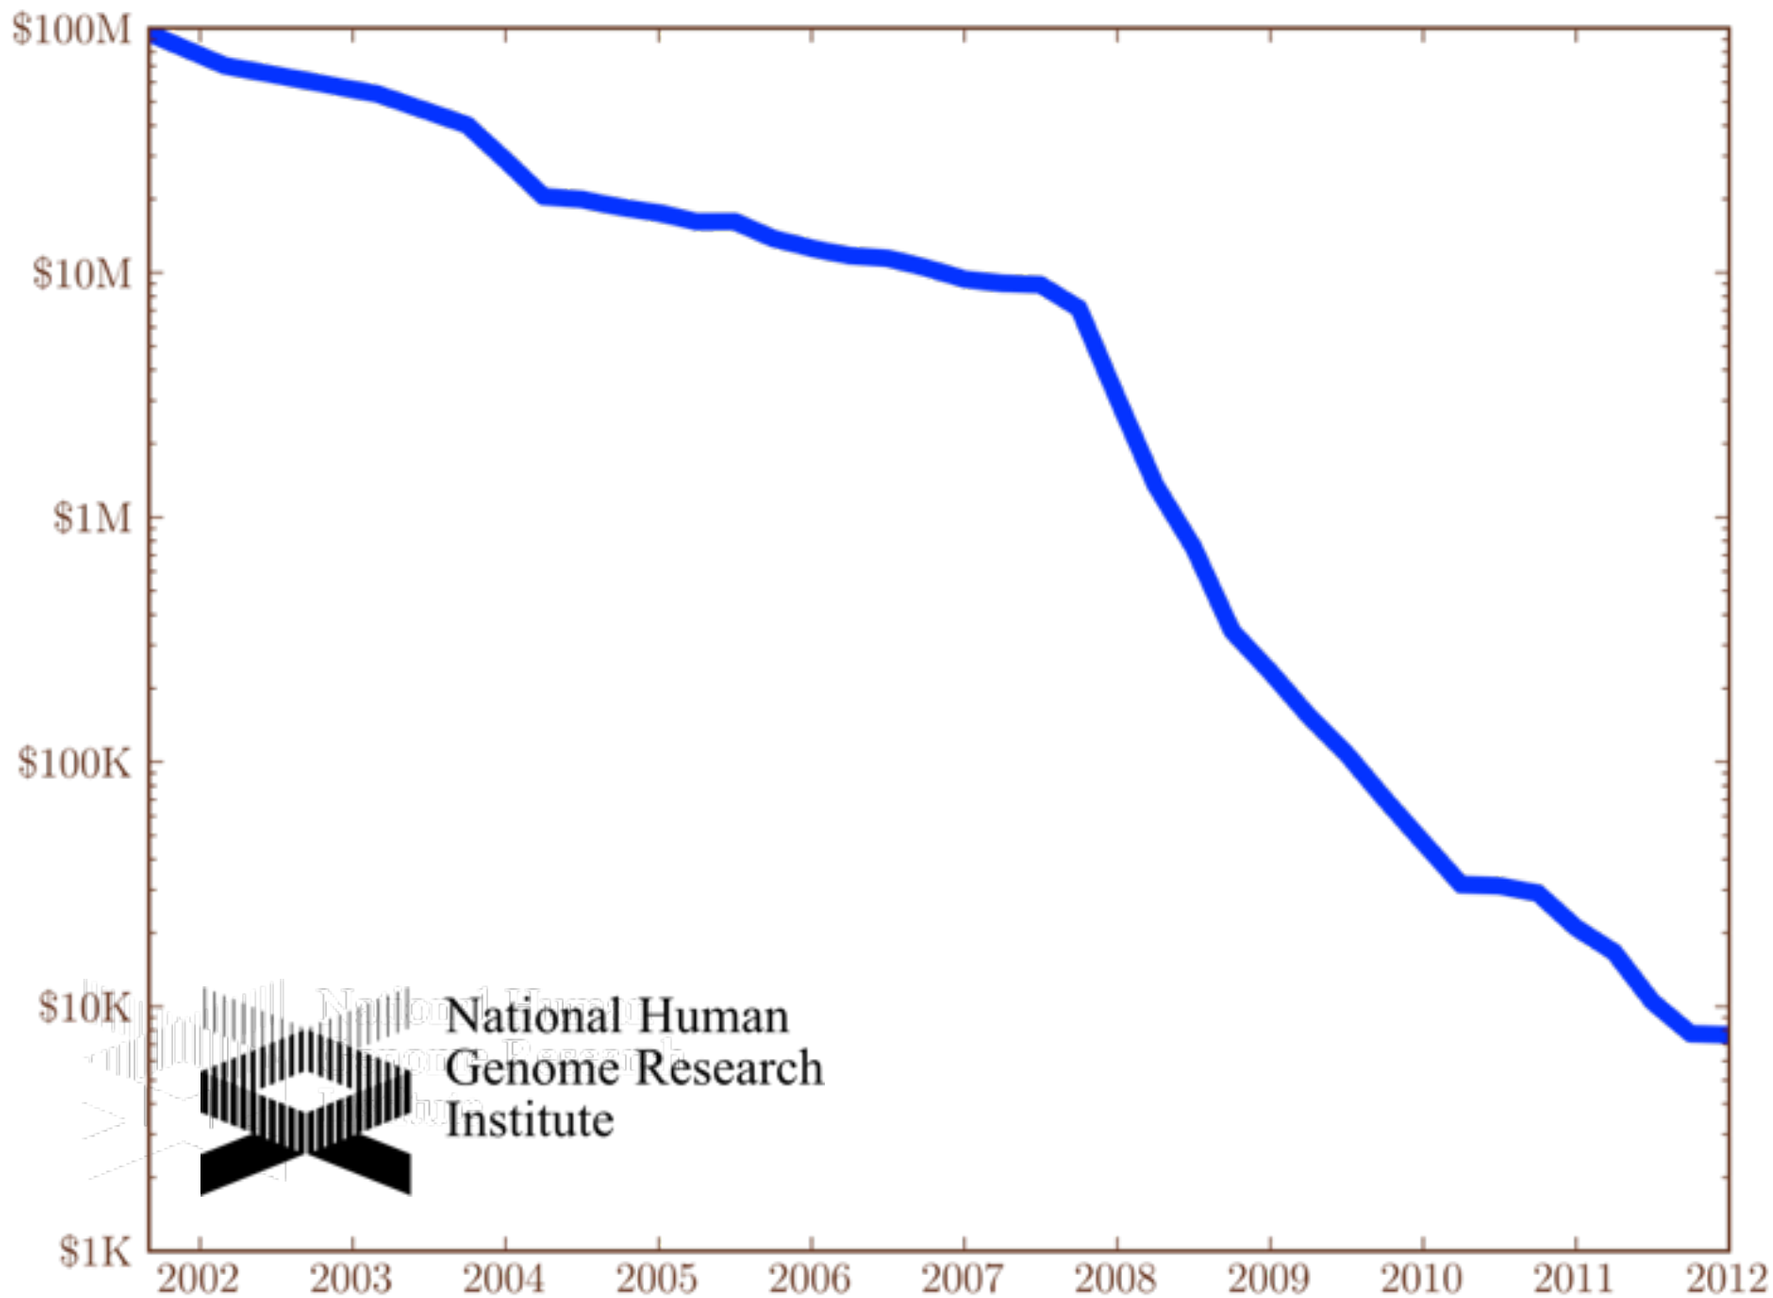

# Эволюция технологий

| Год | Технология | Стоимость |
|---|---|---|
| 2001 | Sanger (ABI) | 300 000 000 $ |
| 2007 | Sanger (ABI) | 10 000 000 $ |
| 2008 | Roche (454) | 2 000 000 $ |
| 2008 | Illumina | 1 000 000 $ |
| 2008 | Illumina | 250 000 $ |
| 2009 | Helicos | 48 000 $ |
| 2012 | Illumina | 5000 $ |
| 2012 | Complete Genomics | 5000 $ |

# Эволюция технологий

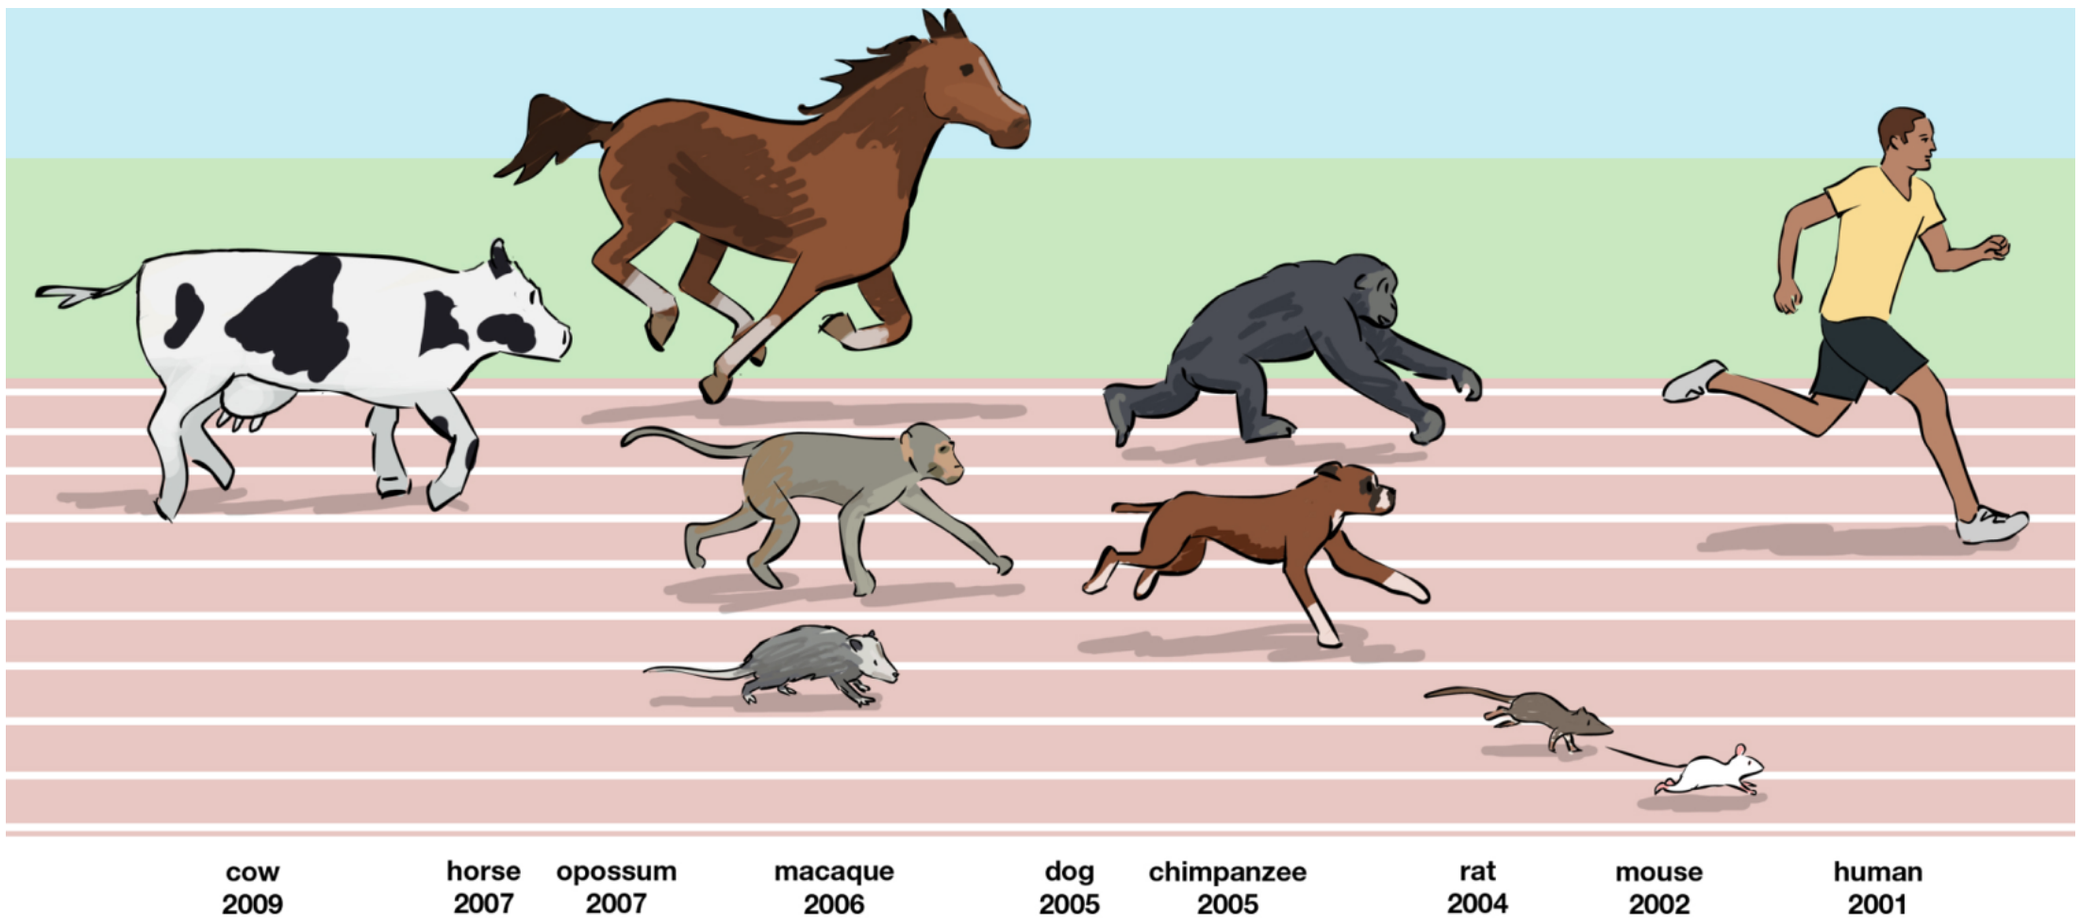

# Будущее

Секвенирование человеческого генома за 1000 долларов может стать реальностью уже в 2013-14 году.

Секвенирование индивидуального генома вскоре станет таким же рутинным делом, как рентгеновский снимок.

# Эволюция технологий

Сегодня: 50 Gbp / день.

Нельзя прочитать ДНК целиком!

Только маленькими фрагментами:

- 100 - 200 букв
- 1-2% ошибок чтения

# Секвенирование

**Чтение фрагментов**
(лабораторная):

Считать множество фрагментов из многих копий одного генома.

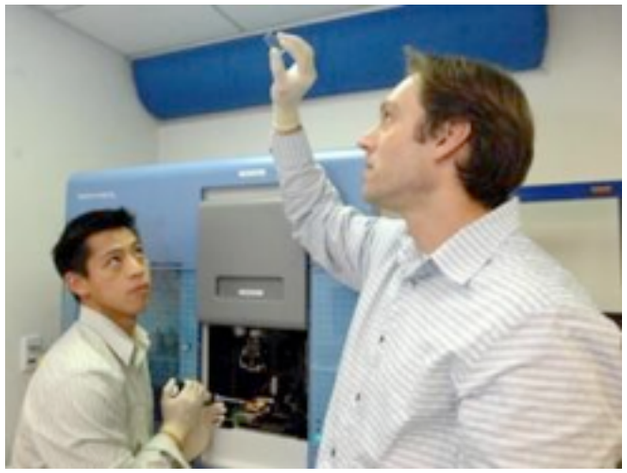

**Сборка фрагментов**
(вычислительная):

Собрать геном из этих ридов с помощью алгоритмов.

# Секвенирование

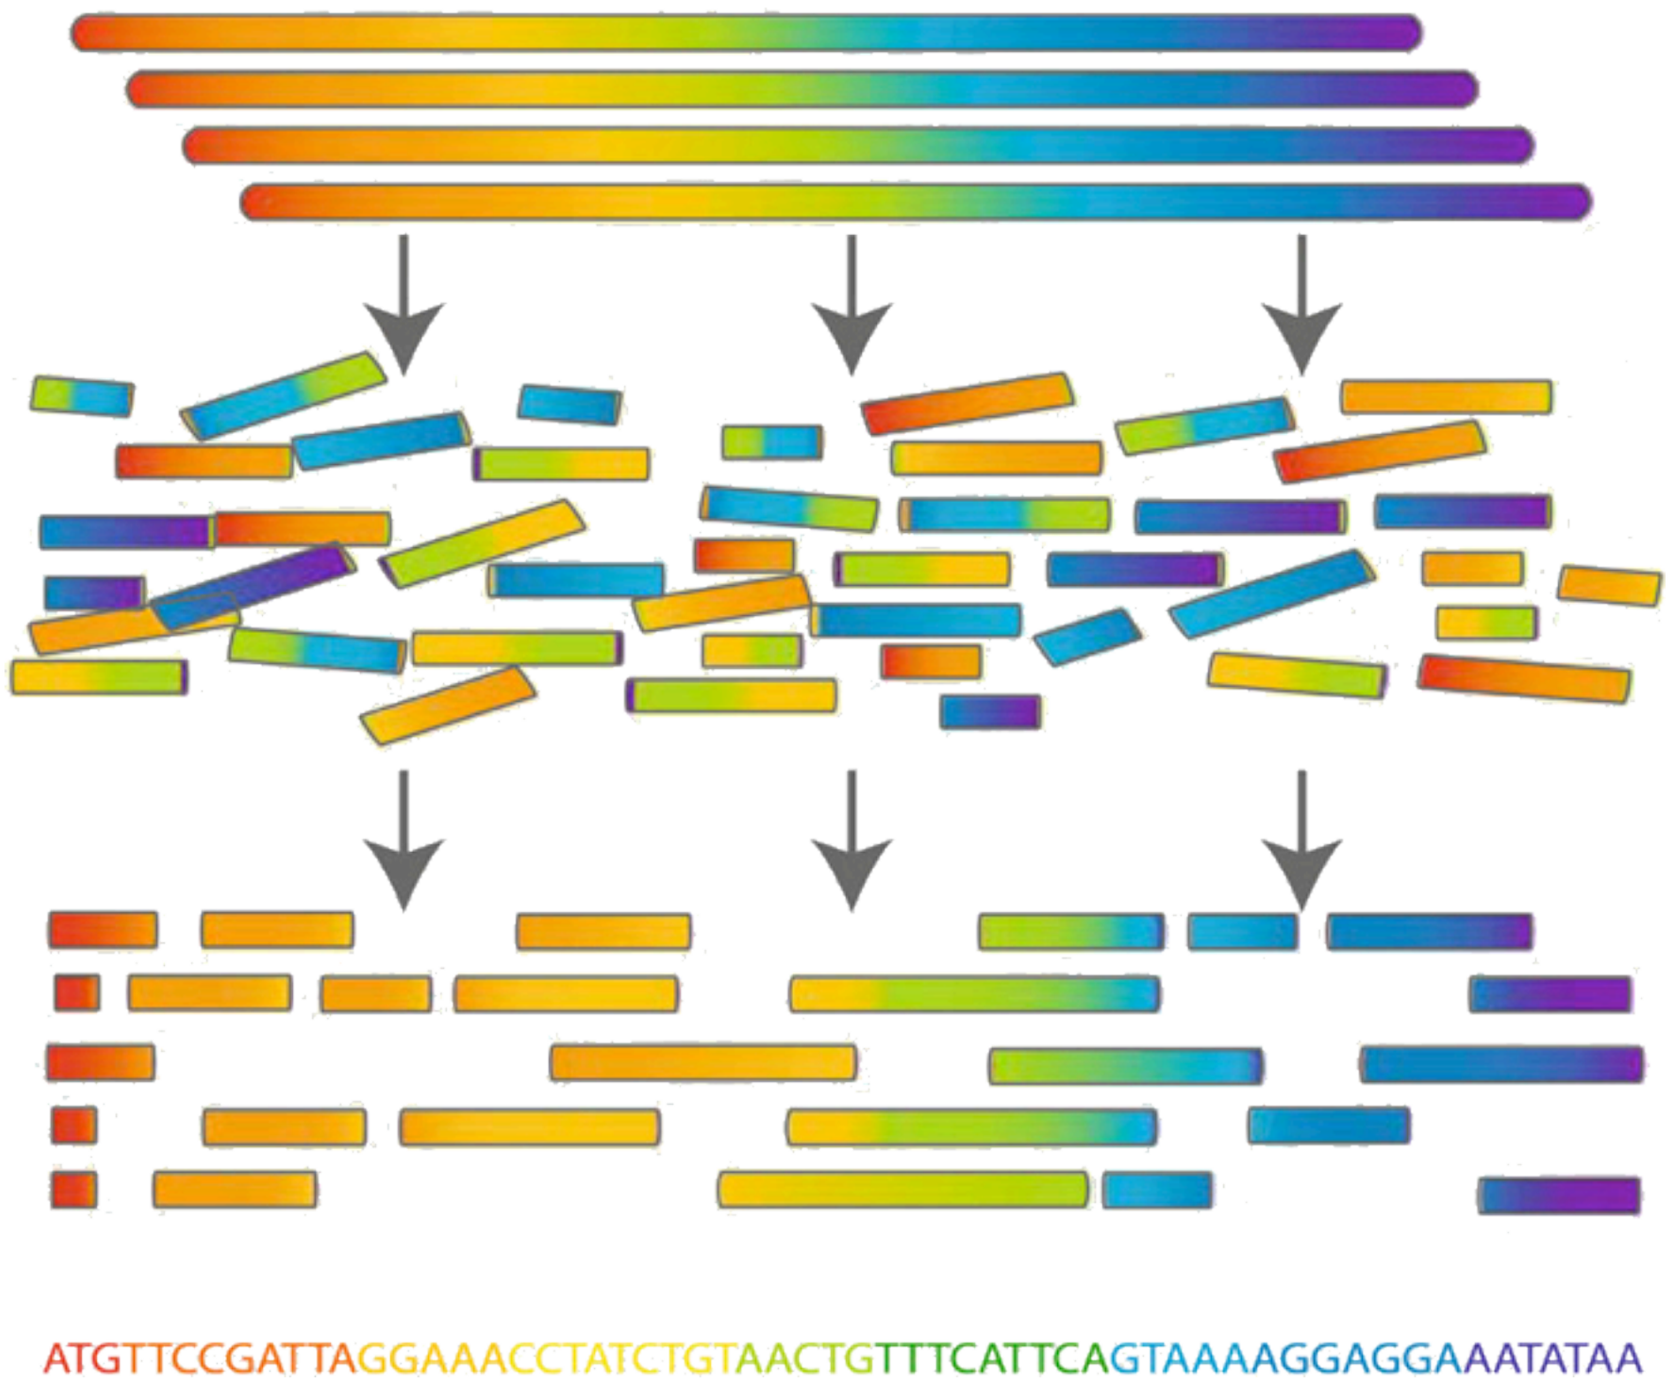

# Next Gen Sequencing

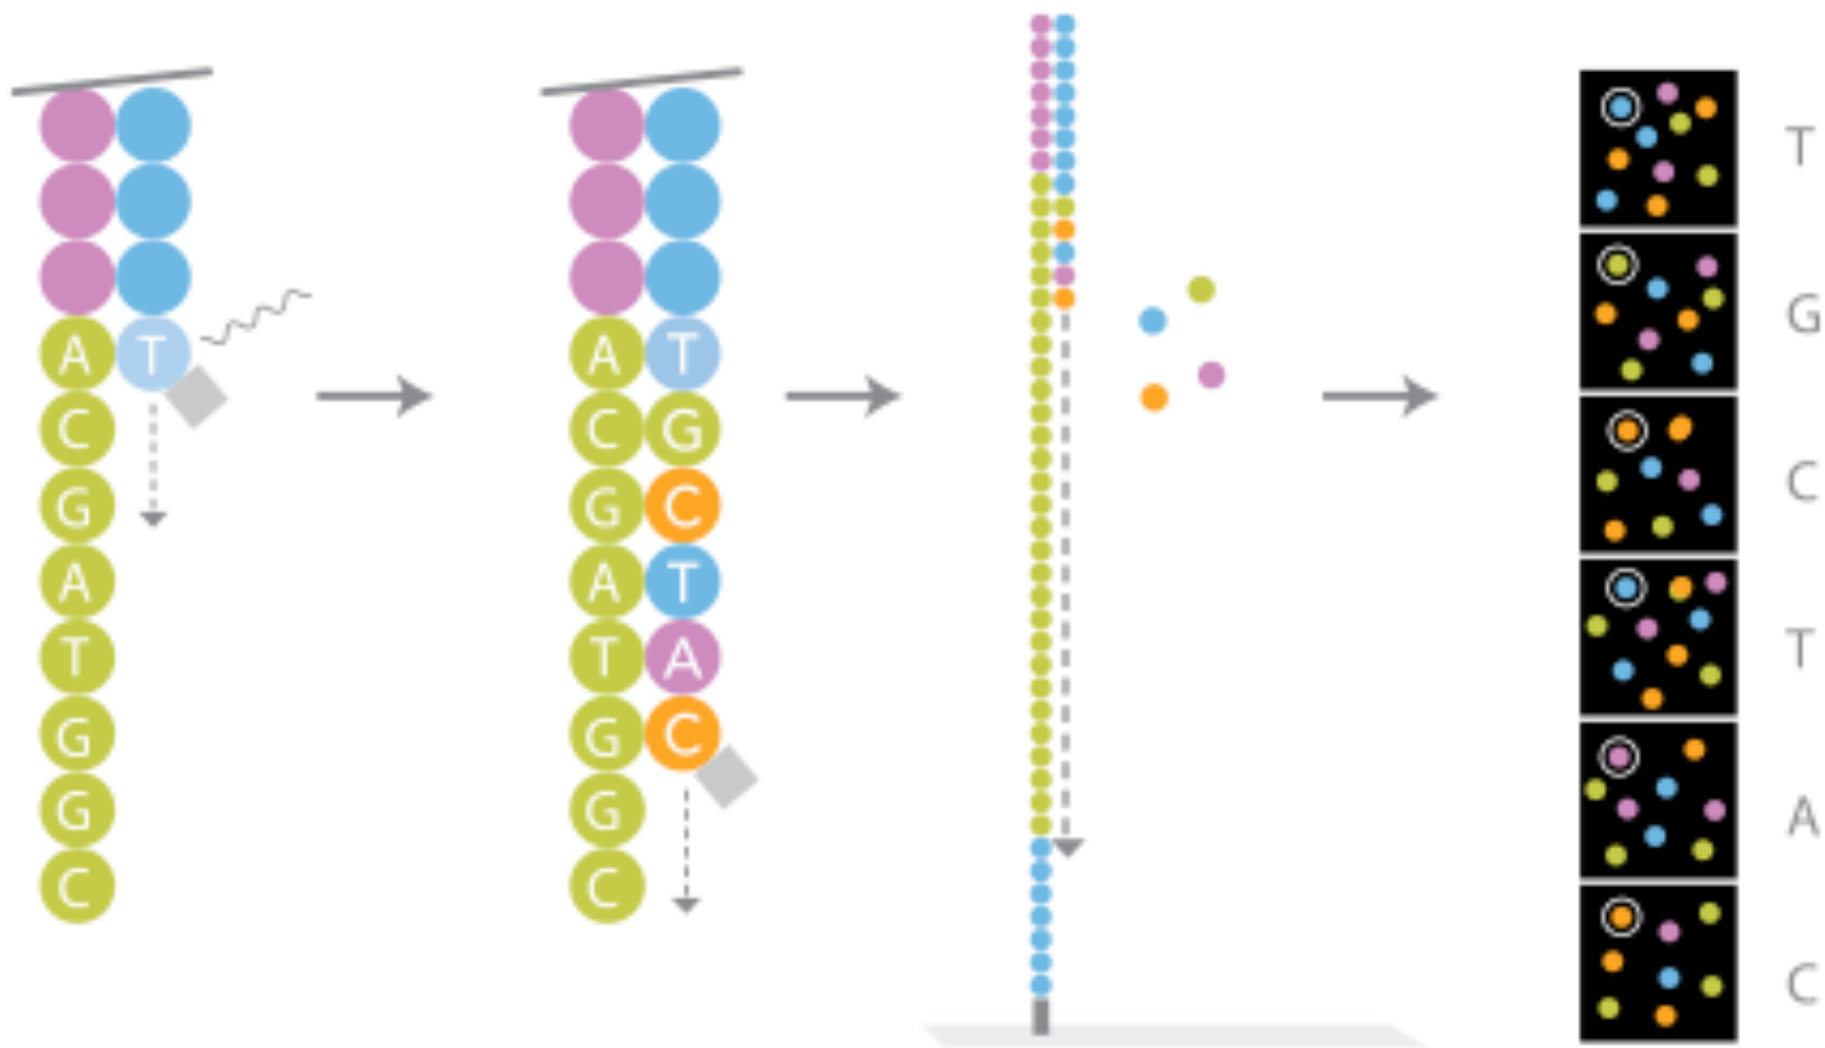

# Short Read Alignment

# Задача

Даны:

шаблоны P суммарной длины N,

текст T длины M.

Найти все позиции вхождения P в T.

# Бор

# Бор

Хранит словарь строк.

# Бор

Хранит словарь строк.

# Бор

Хранит словарь строк.

Trie, префиксное дерево.

# Бор

Хранит словарь строк.

Trie, префиксное дерево.

# Бор

Хранит словарь строк.

Trie, префиксное дерево.

Пример: apple, apropos,
banana, bandana, orange.

# Бор

Хранит словарь строк.

Trie, префиксное дерево.

Пример: apple, apropos, banana, bandana, orange.

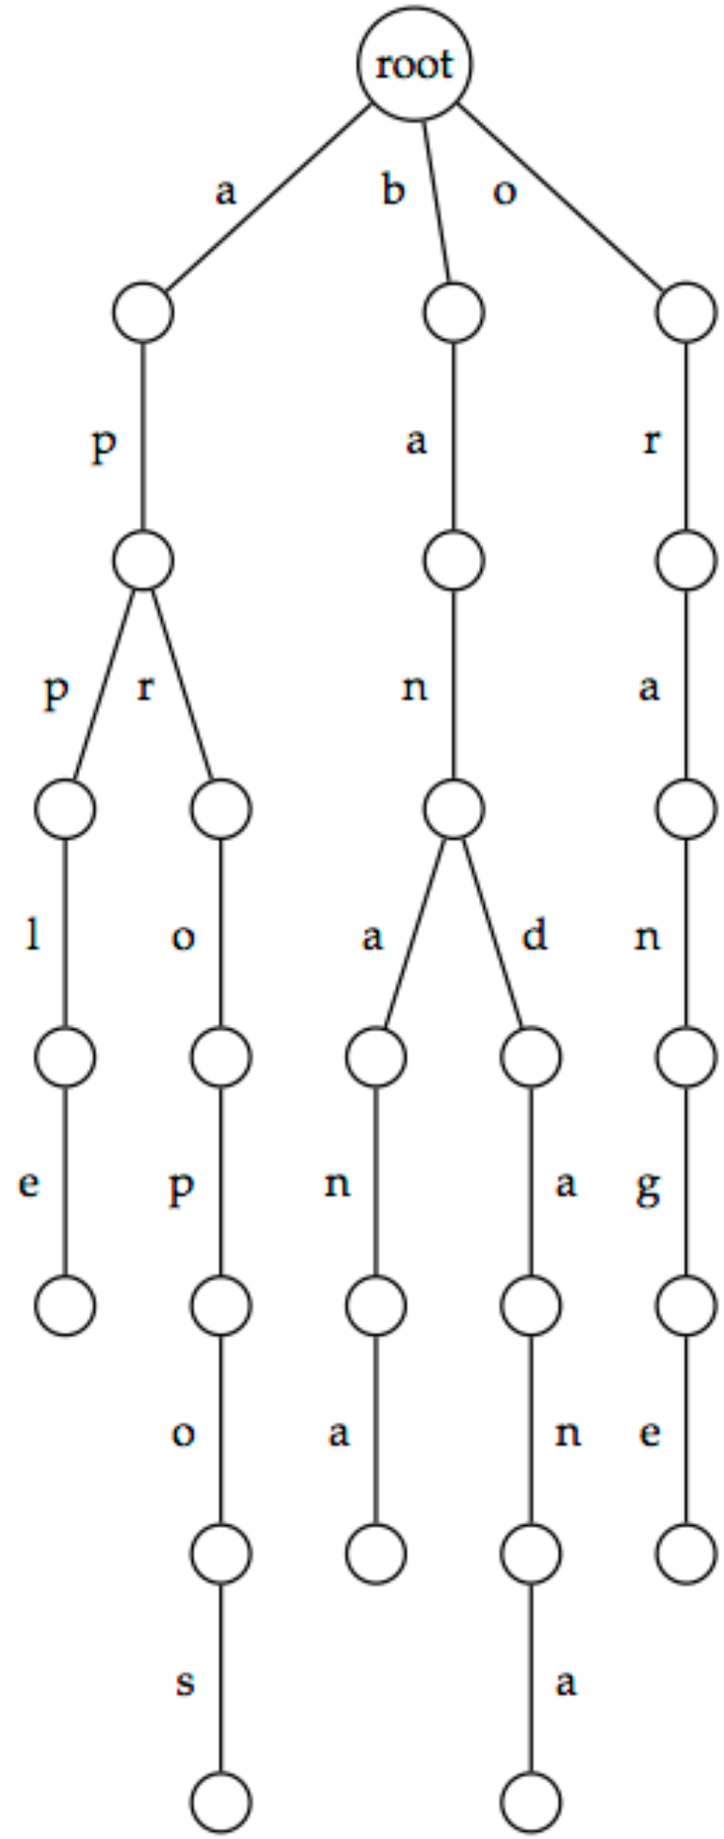

# Ахо – Корасик

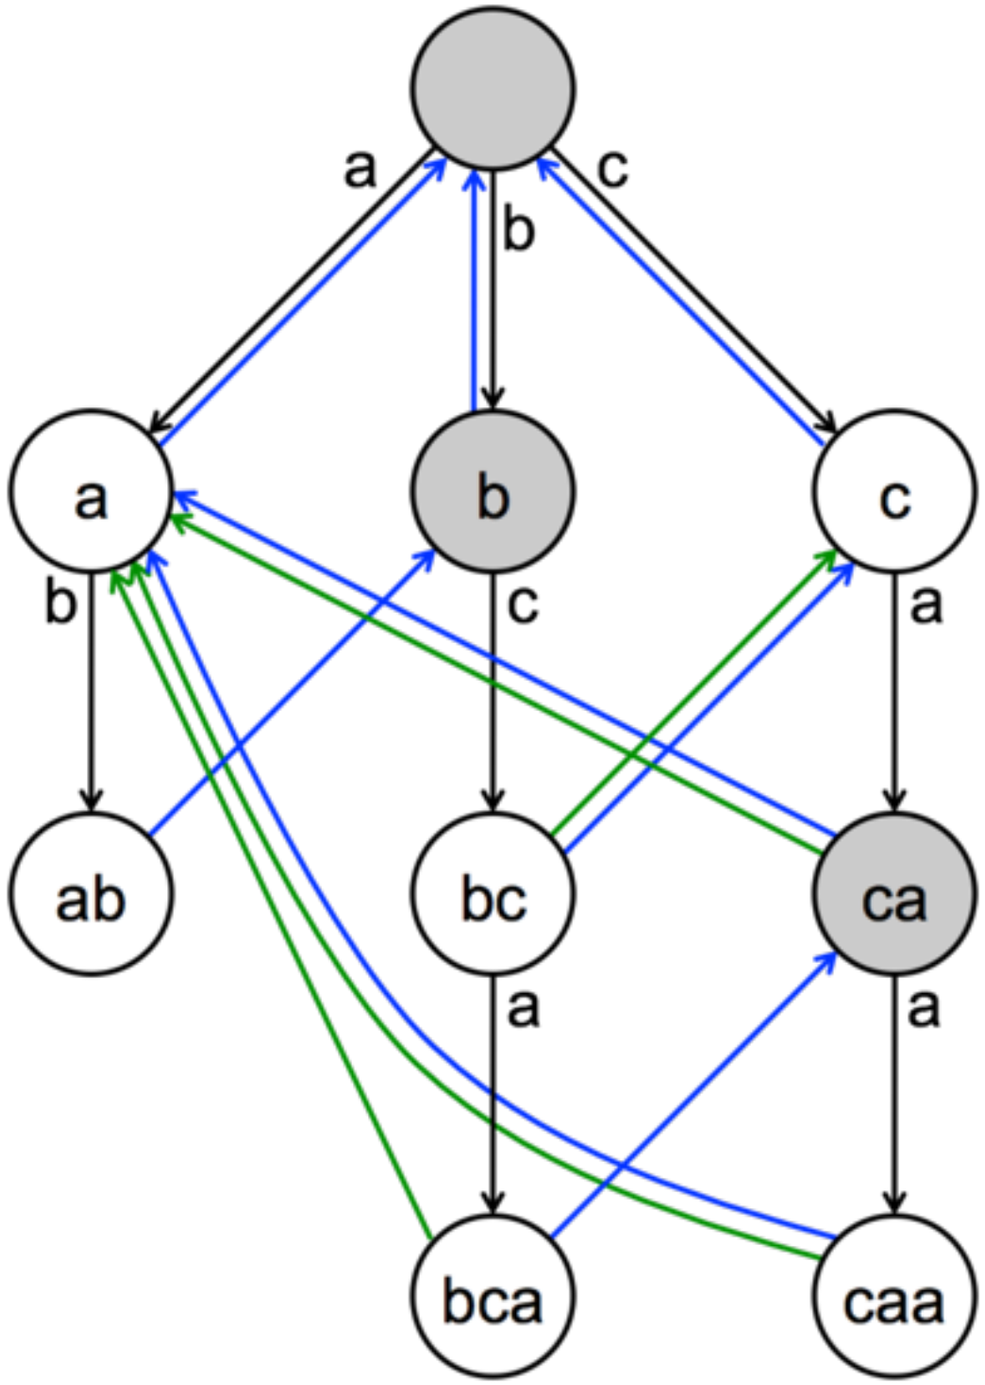


http://e-maxx.ru/algo/aho_corasick

# Новая задача

Даны:

шаблон P длины N,

текст T длины M.

Можно заранее обработать T.

Найти все позиции вхождения P в T.

# Что мы узнали

DNA Sequencing

Бор

Ахо – Корасик

# Формат обучения

12 лекций по воскресеньям

Квизы для самопроверки

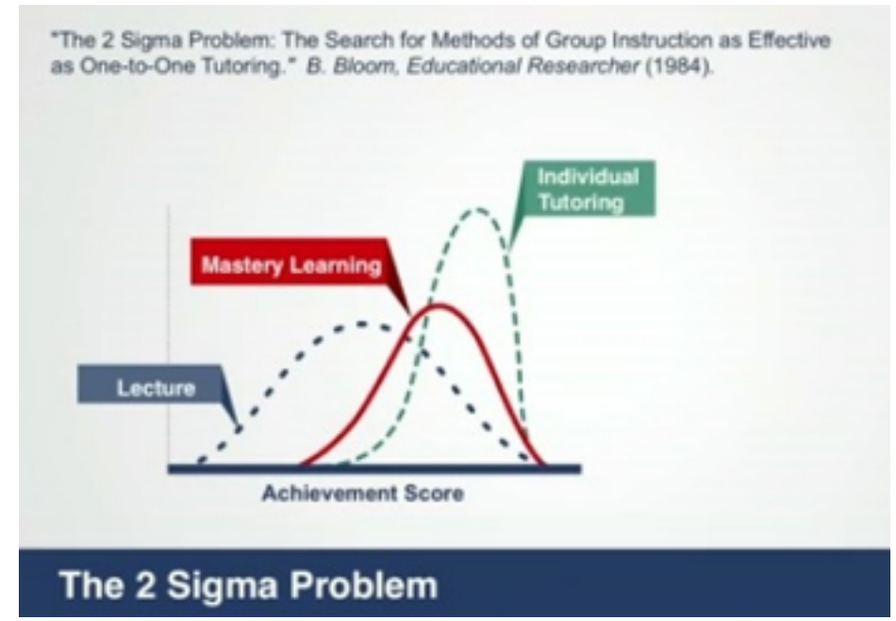


Домашние задания и вопросы онлайн

http://rosalind.info/classes/enroll/ff45302de4/