

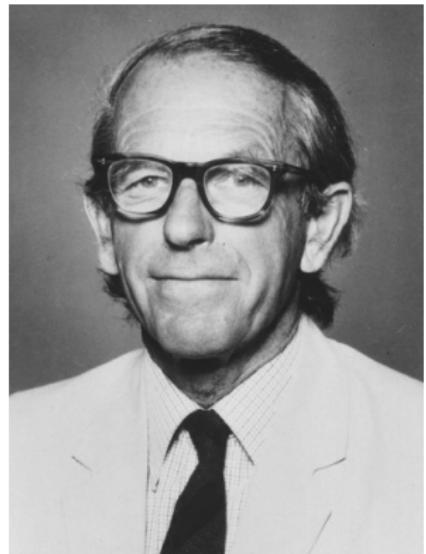
# Нуклеотидные банки данных

Ваня Русинов

# Экскурс в историю секвенирования

# История секвенирования

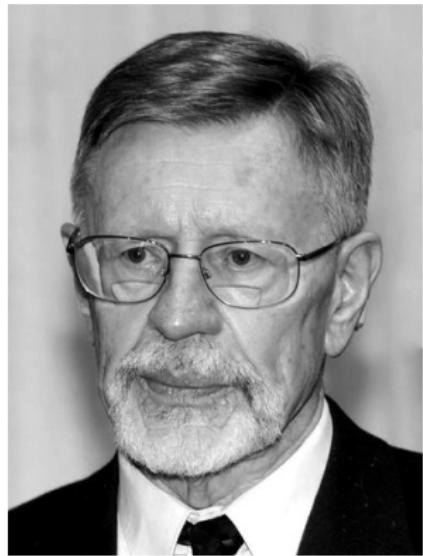
- ▶ 1951 – Первая последовательность:  
бычий инсулин, цепь В (белок!)



Frederick Sanger

# История секвенирования

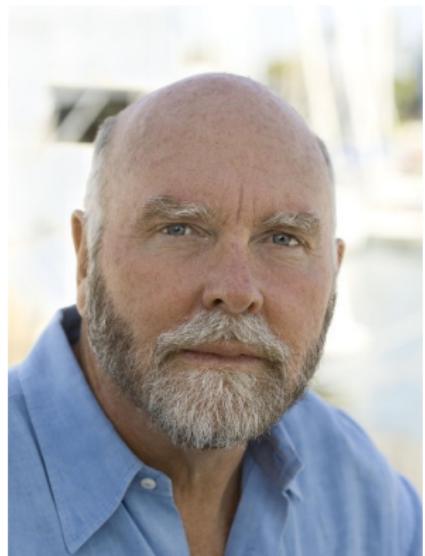
- ▶ 1951 – Первая последовательность:  
бычий инсулин, цепь В (белок!)
- ▶ 1976 – Первый полный геном:  
бактериофаг MS2 (РНК)



Walter Fiers

# История секвенирования

- ▶ 1951 – Первая последовательность:  
бычий инсулин, цепь В (белок!)
- ▶ 1976 – Первый полный геном:  
бактериофаг MS2 (РНК)
- ▶ 1995 – Первый геном бактерии:  
*Haemophilus influenza*



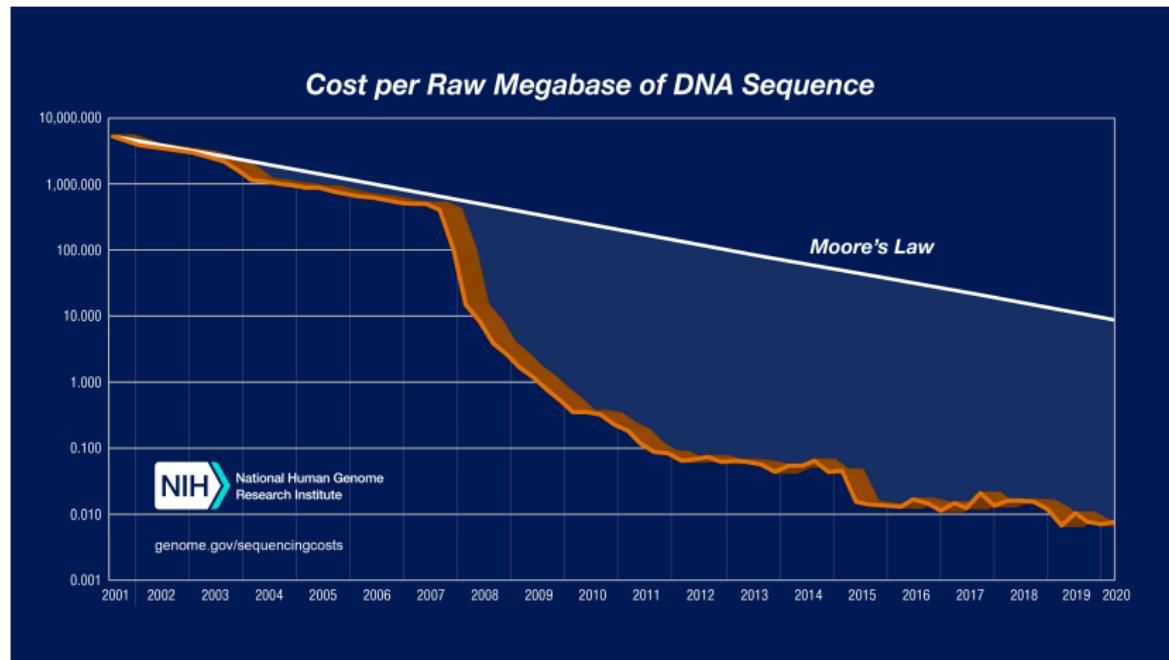
Craig Venter

# История секвенирования

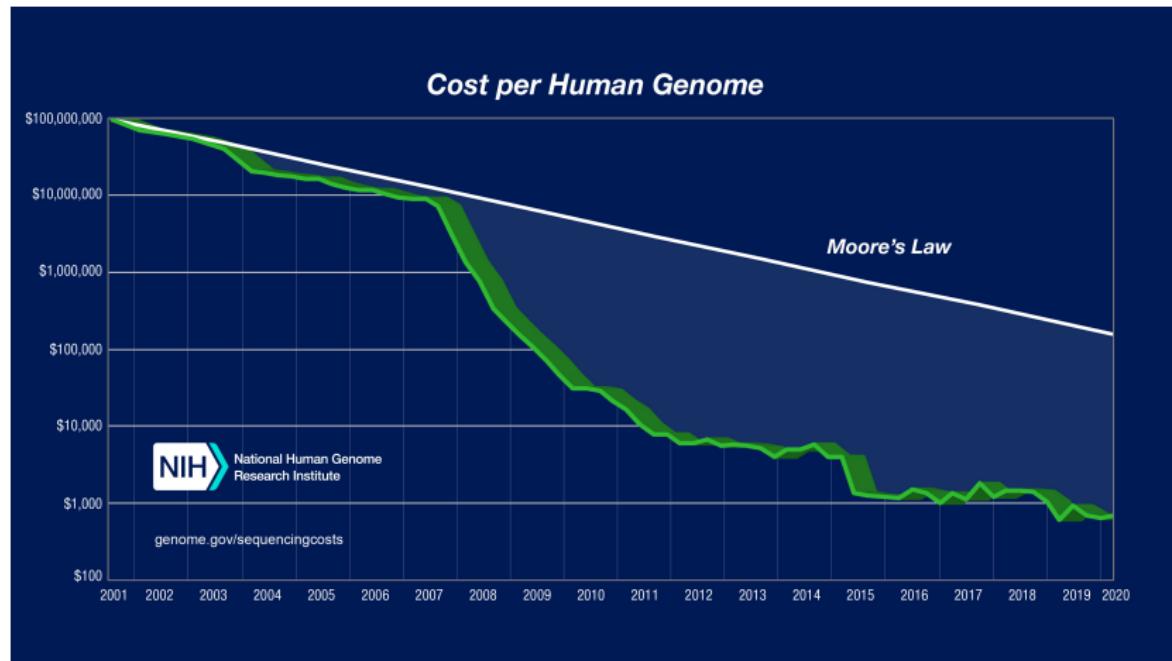
- ▶ 1951 – Первая последовательность:  
бычий инсулин, цепь В (белок!)
- ▶ 1976 – Первый полный геном:  
бактериофаг MS2 (РНК)
- ▶ 1995 – Первый геном бактерии:  
*Haemophilus influenza*
- ▶ 2001 – Первый геном человека:  
международный консорциум vs. Celera  
Genomics

# Next Generation Sequencing

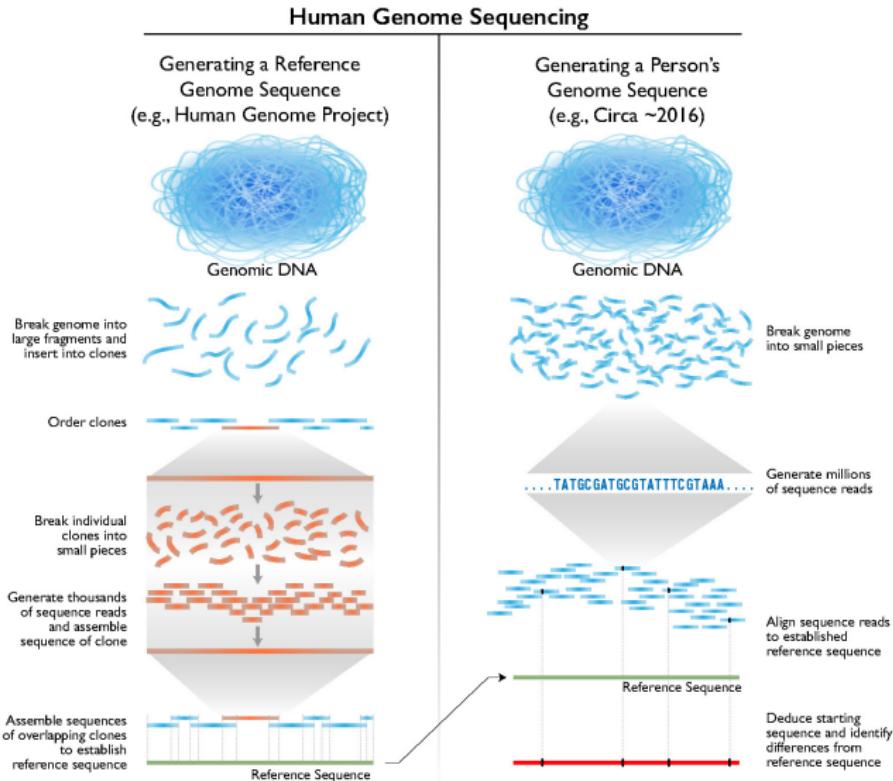
# Стоимость секвенирования



# Стоимость секвенирования



# Sanger vs. NGS



# Термины NGS

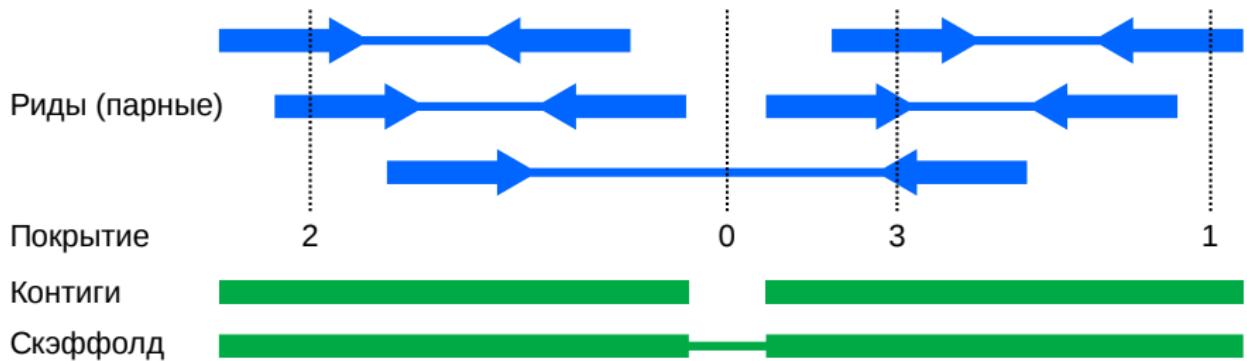
**Прочтение (рид)** последовательность, полученная из секвенатора

**Качество прочтения** величина  $Q = -10 \log_{10} p$ , где  $p$  – вероятность ошибочного прочтения нуклеотида;  $Q$  вычисляется для каждого нуклеотида рида

**Контиг** секвенированный без пропусков фрагмент ДНК, собирается в компьютере из прочтений

**Скэффолд** набор контигов, про которые известно взаимное расположение и примерное расстояние; разрывы заполняют соответствующим количеством букв N

# Сборка NGS



# Показатели качества сборки

**(Среднее) покрытие** среднее число ридов, в которые попал каждый нуклеотид

**N50** длина самого длинного контига, такого, что этот и все более длинные контиги покрывают более половины генома

**L50** номер контига (при упорядочивании по убыванию длины), длина которого равна N50

# Технологии NGS

Table 1 | Main characteristics of current NGS technologies

Technology	Run type			Maximum read length	Quality scores	Error rates
	Single end	Paired end	Mate pair			
Illumina	Yes	Yes	Yes	300 bp	>30	0.0034–1%
SOLiD	Yes	Yes	Yes	75 bp	>30	0.01–1%
IonTorrent	Yes	Yes	No	400 bp	~20	1.78%
454	Yes	Yes	No	~700 bp (up to 1 kb)	>20	1.07–1.7%
Nanopore	Yes	No	No	5.4–10 kb	NA	10–40%
PacBio	Yes	No	No	~15 kb (up to 40 kb)	<10	5–10%

Escalona, Rocha, Posada. *Nat Rev Genet.* 2016; 17(8): 459–469. PMID: 27320129; PMCID: PMC5224698.

## Масштабы бедствия

По данным NCBI Genome, на данный момент секвенированы (или в процессе секвенирования) геномы:

- ▶ 282 246 прокариот
- ▶ 41 416 вирусов
- ▶ 24 437 плазмид
- ▶ 17 234 органелл
- ▶ 13 199 эукариот

NCBI Genome содержит далеко не все секвенированные геномы.

# Массовые геномные проекты

...

- 2013 100000 геномов людей
- 2012 100000 геномов патогенных бактерий
- 2012 1000 геномов грибов
- 2011 5000 геномов насекомых
- 2010 10000 геномов позвоночных
- 2009 1000 геномов растений
- 2008 3000 геномов риса
- 2008 1000 геномов людей
- 2008 1001 геном Арабидопсиса

...

# Что секвенируют?

- ▶ Геномы
- ▶ Экзомы
- ▶ Транскриптомы
- ▶ Метиломы
- ▶ Метагеномы
- ▶ Сайты связывания ДНК белком (ChIP-seq)
- ▶ Сближенные участки хромосом (HiC)
- ▶ И многое другое

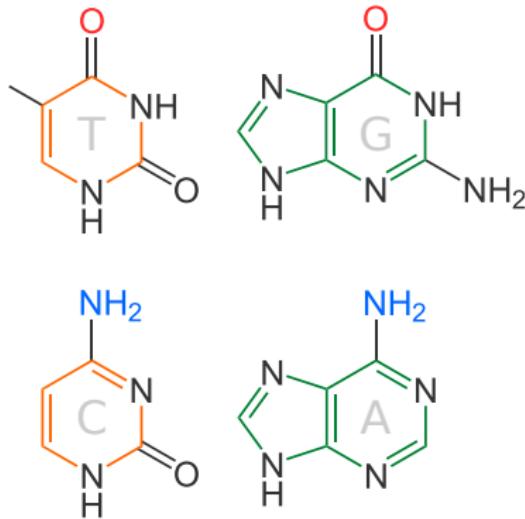
# Нуклеотидные банки данных

## Соглашения о хранении последовательностей

- ▶ Хранят последовательность однобуквенных обозначений нуклеотидов,
- ▶ записанную от 5'-конца к 3'-концу
- ▶ только для одной цепи ДНК.
- ▶ В случае РНК урацилы тоже обозначают буквой Т.
- ▶ Нуклеотиды нумеруют, начиная с 1 (а не 0).
- ▶ Координаты указывают включительно с обоих концов.

# Нуклеотидные коды IUPAC

Код	Значение	Мнемоническое правило
A	A	Adenine
C	C	Cytosine
G	G	Guanine
T	T	Thymine
K	G или T	Keto
M	A или C	aMino
R	A или G	puRine
Y	C или T	pYrimidine
S	C или G	Strong interaction
W	A или T	Weak interaction
B	не A	после A по алфавиту
D	не C	после C по алфавиту
H	не G	после G по алфавиту
V	не T	после T и U по алфавиту
N	любой	aNy



Nomenclature for incompletely specified bases in nucleic acid sequences. Recommendations 1984.  
PNAS. 1986;83:4–8. PMID: 2417239; PMCID: PMC322779.

# Типы баз данных

**Архивные** записи создают сами экспериментаторы, они же отвечают за достоверность информации

**Курируемые** за создание и редактирование записей отвечают специальные люди, кураторы

**Автоматические** записи создаются автоматически компьютерными программами

# INSDC ([www.insdc.org](http://www.insdc.org))

International Nucleotide Sequence Database Collaboration:

- ▶ Объединяет 3 крупнейших нуклеотидных архива: GenBank, ENA, DDBJ
- ▶ Ежедневный обмен данными
- ▶ Единый формат таблицы локальных особенностей
- ▶ Рекомендации по использованию терминов и ключевых слов в аннотациях
- ▶ И некоторые прочие унификации (например, таблицы генетического кода)



# Структура данных в INSDC

Data type	DDBJ	EMBL-EBI	NCBI
Next generation reads	<a href="#">Sequence Read Archive</a>	European Nucleotide Archive ( <a href="#">ENA</a> )	<a href="#">Sequence Read Archive</a>
Capillary reads	<a href="#">Trace Archive</a>		<a href="#">Trace Archive</a>
Annotated sequences	<a href="#">DDBJ</a>		<a href="#">GenBank</a>
Samples	<a href="#">BioSample</a>		<a href="#">BioSample</a>
Studies	<a href="#">BioProject</a>		<a href="#">BioProject</a>

# ENA data domains

**Study/Project** информация о проекте по секвенированию

**Sample** информация об образце – источнике биологического материала

**Read** прочтения NGS и описание методики секвенирования

**Assembly** информация о сборке скэффолдов и хромосом из ридов и контигов

**Analysis** производные данные о сборке или аннотации

**Contig set** содержит ссылки на записи с контигами

**Sequence** собранные и аннотированные последовательности

**Taxon** таксономическая информация

**Checklist** описание требований к метаданным на момент создания записи о проекте

# ENA data classes

**STD** собранные и аннотированные последовательности

**CON** скэффолды

**WGS** геномные контиги

**TSA** транскриптомные контиги

**HTG** High Throughput Genomic data

**HTC** High Throughput Transcriptomic data

**EST** Expressed Sequence Tags

**GSS** Genome Survey Sequence

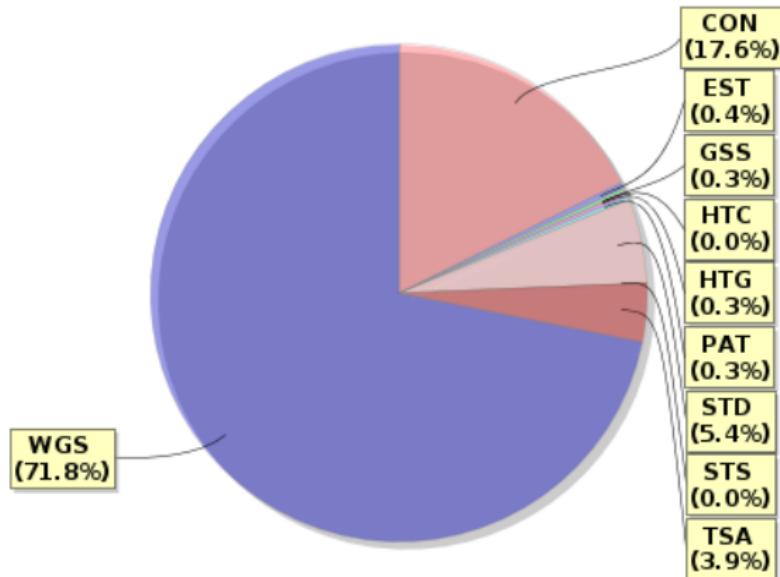
**STS** Sequence Tagged Site

**PAT** последовательности из патентов

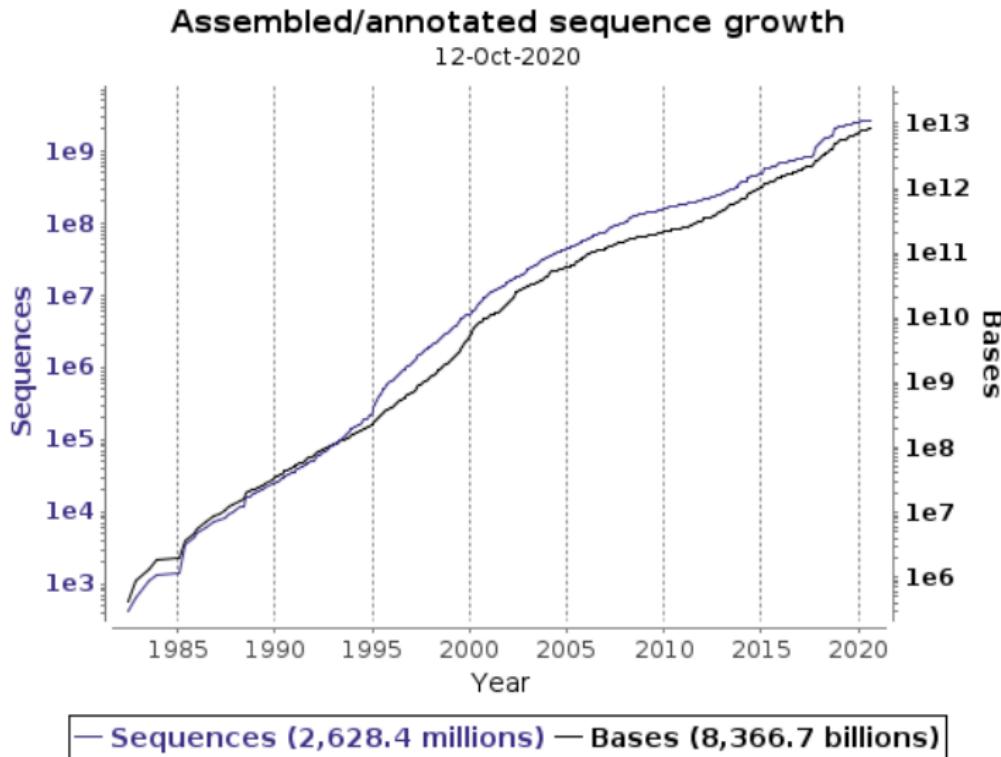
# ENA: распределение записей по классам

Assembled/annotated sequence bases by dataclass

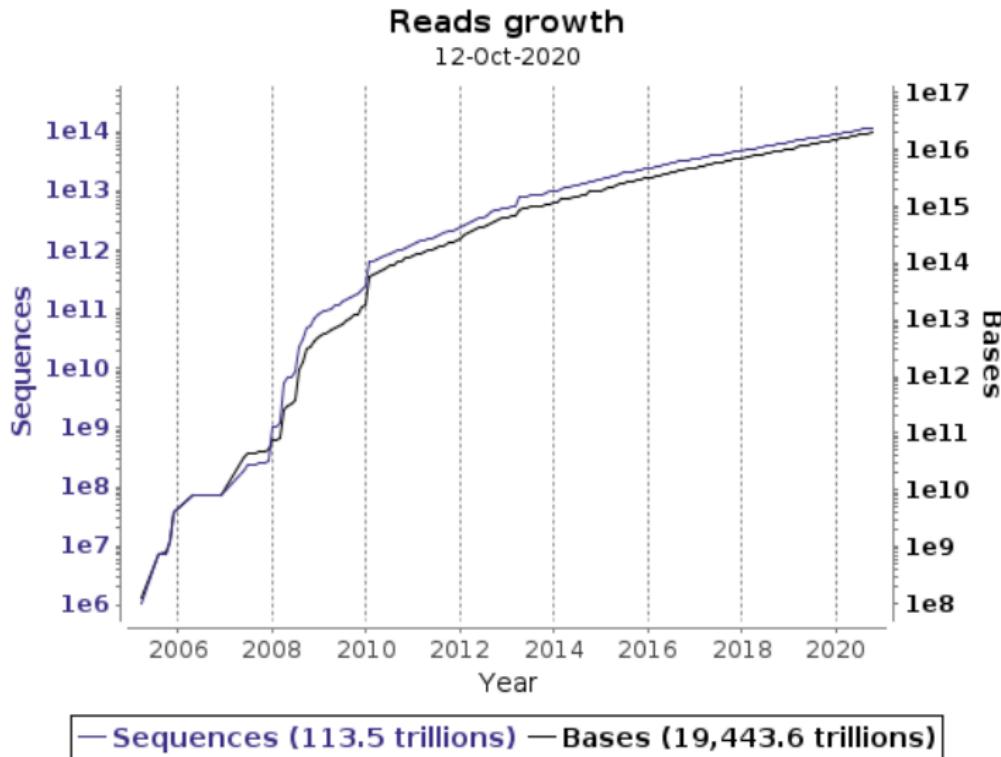
12-Oct-2020



# ENA: рост числа записей



# ENA: увеличение объема SRA



# Формат записи в ENA

ID LR694071; SV 1; linear; genomic DNA; STD; VRT; 335 BP.  
XX  
AC LR694071;  
XX  
PR Project:PRJEB20083;  
XX  
DT 01-AUG-2019 (Rel. 141, Created)  
DT 12-SEP-2019 (Rel. 142, Last updated, Version 2)  
XX  
DE Carcharodon carcharias isolate C\_car\_delaware\_2007 genome assembly,  
DE chromosome: 1  
XX  
KW .  
XX  
OS Carcharodon carcharias (great white shark)  
OC Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Chondrichthyes;  
OC Elasmobranchii; Galeomorphii; Galeoidea; Lamniformes; Alopiidae;  
OC Carcharodon.  
XX  
RN [1]  
RA Canner M., Saneer T.;  
RT ;  
RL Submitted (31-JUL-2019) to the INSDC.  
RL Saneer-Weeksbooth Bashhouse  
XX  
DR MD5; a7e1a34e45308b36003800689dc43934.  
DR BioSample; SAMN04526268.  
XX  
FH Key Location/Qualifiers  
FH  
FT source 1..335  
FT /organism="Carcharodon carcharias"  
FT /chromosome="1"  
FT /isolate="C\_car\_delaware\_2007"  
FT /mol\_type="genomic DNA"  
FT /db\_xref="taxon:13397"  
XX  
SQ Sequence 335 BP; 323 A; 12 C; 0 G; 0 T; 0 other;  
caaaaaaaaaaaaaaaaaaaaaaaaaaaaaaaaac 60  
...  
caaaaaaaaaaaaaaaaaaaaaaaaac 335  
//

# Формат записи в GenBank

```
LOCUS      LR694071          335 bp    DNA     linear   VRT 12-SEP-2019
DEFINITION Carcharodon carcharias isolate C_car_delaware_2007 genome assembly,
chromosome: 1.
ACCESSION  LR694071
VERSION    LR694071.1
DBLINK     BioProject: PRJEB20083
            BioSample: SAMN04526268
KEYWORDS   .
SOURCE     Carcharodon carcharias (great white shark)
ORGANISM   Carcharodon carcharias
            Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Chondrichthyes;
            Elasmobranchii; Galeomorphii; Galeoidea; Lamniformes; Alopiidae;
            Carcharodon.
REFERENCE  1
AUTHORS   Canner,M. and Saneer,T.
TITLE     Direct Submission
JOURNAL   Submitted (31-JUL-2019) Saneer-Weeksbooth Bashhouse
FEATURES  Location/Qualifiers
source    1..335
            /organism="Carcharodon carcharias"
            /mol_type="genomic DNA"
            /isolate="C_car_delaware_2007"
            /db_xref="taxon:13397"
            /chromosome="1"
ORIGIN    1 caaaaaaaaaaaaaaaa aaaaaaaaaaaa aaaaaaaaaaaa aaaaaaaaaaaa aaaaaaaaaac
            ...
            301 caaaaaaaaaaaaaaaa aaaaaaaaaaaa aaaac
//
```

# Базы метаданных NCBI

**Taxonomy** Таксономическая база данных

**BioProject** Содержит информацию о проектах секвенирования

**BioSample** Содержит информацию об образце, из которого получена НК

**Assembly** Информация о сборке, ссылки на последовательности контигов, скэффолдов, и репликонов

**Genome** Информация о геномах организмов на основании имеющихся геномных сборок

## RefSeq

Нуклеотидная база данных в NCBI, созданная для снижения избыточности и унификации аннотаций.

- ▶ Автоматическая (по большей части) база данных
- ▶ Свой формат AC (содержат \_)
- ▶ Значительно меньше вырожденность, чем в GenBank (меньше повторяющихся последовательностей)
- ▶ Аннотации валидируются и обновляются
- ▶ Аннотации более унифицированные, чем в GenBank
- ▶ Некоторые записи даже курируются
- ▶ Формат записей практически идентичен GenBank

## Nucleotide

Для упрощения поиска нуклеотидных последовательностей через web-интерфейс и Entrez (nuccore).

- ▶ Содержит нуклеотидные записи из: INSDC (GenBank/ENA/DDBJ), RefSeq, PDB, TPA (Third Party Annotation)
- ▶ Одна и та же последовательность может встречаться много раз (например, идентичные записи INSDC и RefSeq)
- ▶ Содержит все нуклеотидные последовательности в NCBI (после слияния с GSS и EST в июле 2019).

## Nucleotide collection (nr/nt)

- ▶ Содержит только последовательности и их идентификаторы в INSDC, RefSeq, PDB.
- ▶ Идентичные последовательности кластеризуются.
- ▶ Служит для поиска с помощью BLAST.

# Поиск по аннотациям и загрузка данных

- NCBI**
1. Глобальный поиск по базам NCBI  
(<https://www.ncbi.nlm.nih.gov/search>)
  2. E-Utilities – Web API к системе Entrez  
(<https://www.ncbi.nlm.nih.gov/books/NBK25501/?term=e-utilities>)
  3. Batch Entrez – по файлу со списком идентификаторов  
(<https://www.ncbi.nlm.nih.gov/sites/batchentrez>)
  4. FTP (<ftp://ftp.ncbi.nlm.nih.gov/>)
- ENA**
1. Search & Browse (<https://www.ebi.ac.uk/ena/browse>)
  2. Advanced search (<https://www.ebi.ac.uk/ena/browser/advanced-search>)
  3. REST URLs (<https://www.ebi.ac.uk/ena/browse/data-retrieval-rest>)
- DDBJ**
1. Search & Analysis (<https://www.ddbj.nig.ac.jp/services-e.html>)
  2. ARSA (<http://ddbj.nig.ac.jp/arsa>)
  3. GetEntry (<http://getentry.ddbj.nig.ac.jp/top-e.html>)
  4. FTP (<ftp://ftp.ddbj.nig.ac.jp/>)