

# Банки информации в молекулярной биологии

С.А.Спирин

11/III – 2006

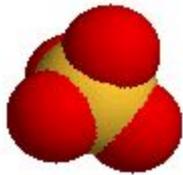
# Пример информации

## последовательность ДНК


gatcaacactacttgacttcaagacttaccataaagaaaactatagtgtggtattggcaa  
aagacaagacaaatagatcaacataacaaaataaagggccatgaaatagaccatatagt  
caattgattttttgacaaagaaggattggcaatagaatgggggtaaagatagtcttctcaac  
aaacggtaccagaatgactgaatacccacatgcaaaaagaaaaagaaatgaacctagaca  
cagatcttatacagttcacaaaaatgtaactcaaatgaatcatagacctaaatataata  
ttcaagactataaaaccctaaaatataacataggggaaaatctaaacaatcttgagtttg  
ttaatgacttttttagatacaataccaaaggcaggatccaggaaagaatcgataagctggg  
cttcattaaaattaaaatatttctgctctatgaagccactgtcaagagaaggaaaaggca  
agccatagactgggagaaaatatttacaanaagacatacatgataaaggactattatccaa  
aatgtacaagaactctaaaaacttaacaataagaaaacaaacccaactaaaaactggg  
ccaaagatcttaacagatatattaccaagaagatacacagatggcaaataagcataaaa  
agattaaccacatcatacgtcattaagaaattgcaaattaaaacaacaatgagacaccat  
tatacacctagtagaatgacccaaatccagattactgacataatcaaatgctgacaagga  
tgtggagaaacaggaactgccattcttggggttgtgggaatgccaaatgggtatgcctgctt  
tggaagacagcttggtggtttcttacaacactaagcatactcttaccaaaagatcgagca

# Вообще-то ДНК — это молекула...

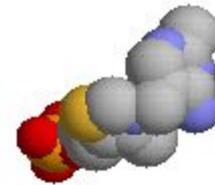
Примеры молекул:



Сульфат

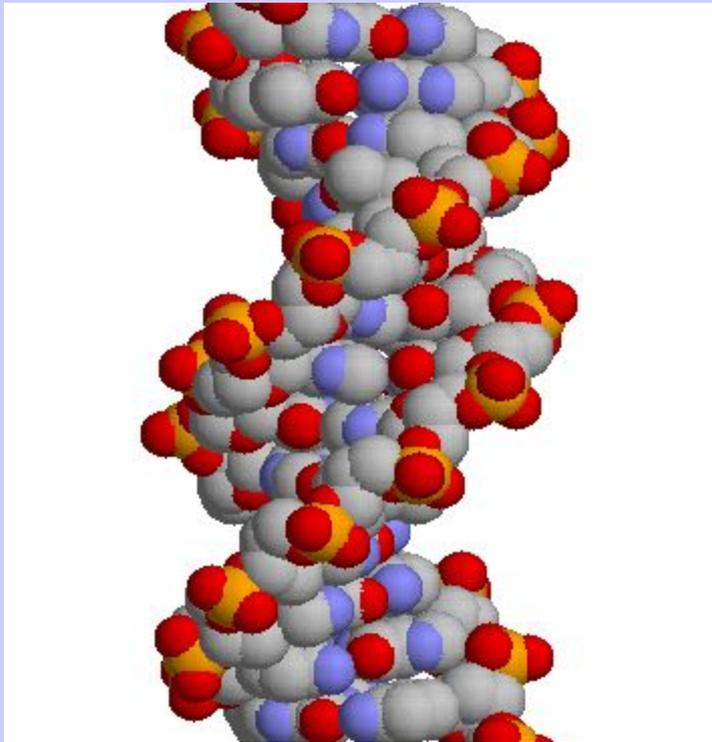


Фенол

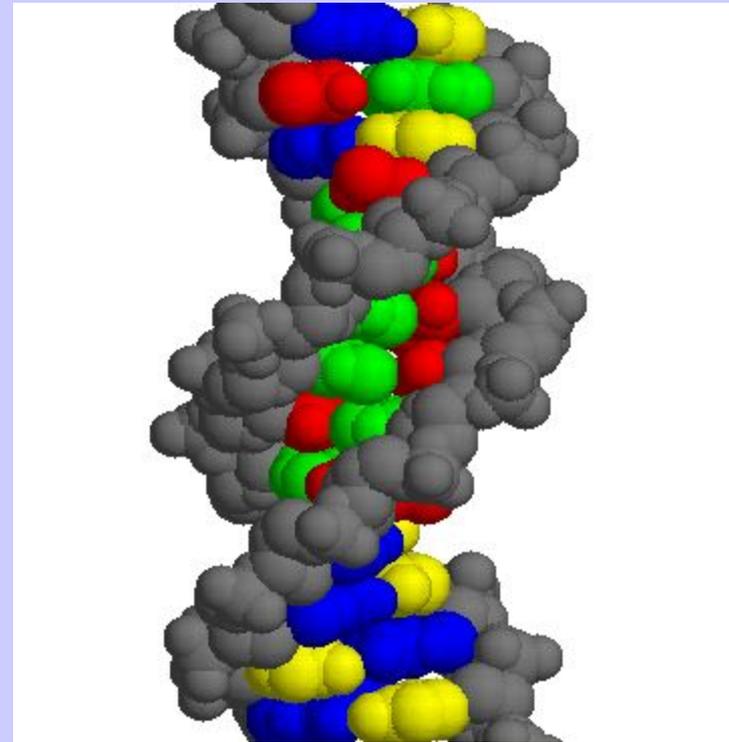


Фосфат тиаминa  
(атомы водорода не показаны)

# Молекула ДНК

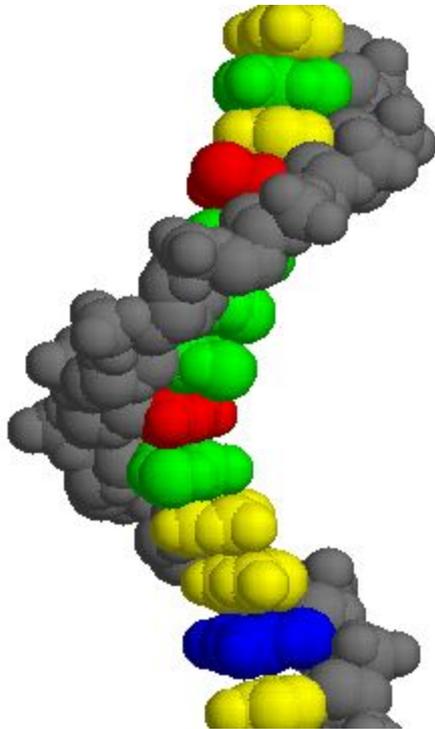


C N O P



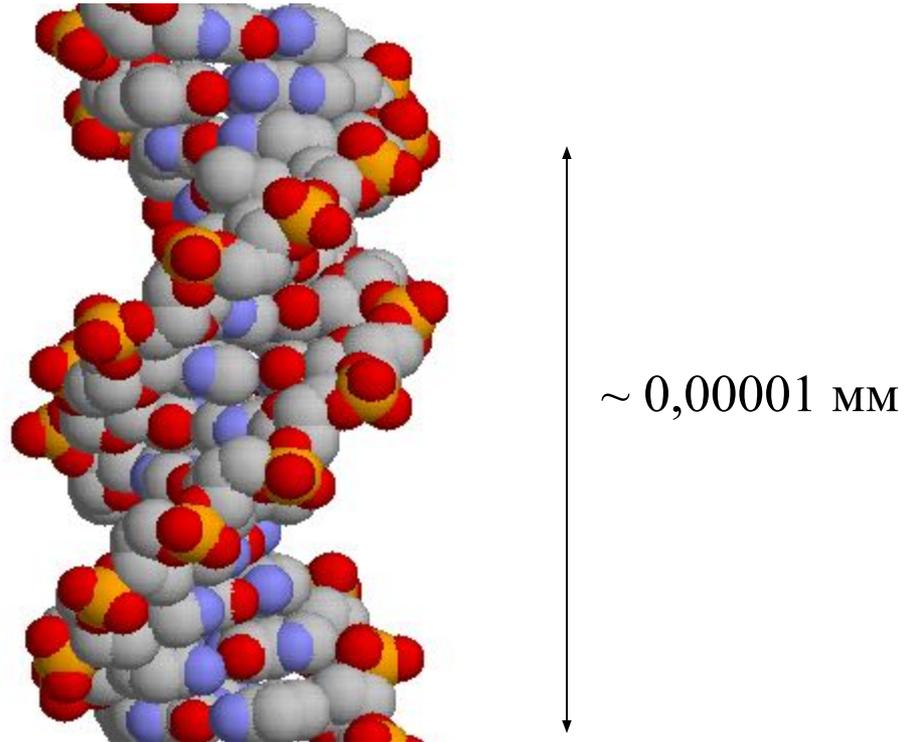
A C G T

Одну нить ДНК можно условно обозначить последовательностью букв



**CGCCATAAATCAC**

# Детали строения молекул в микроскоп не видны!



Существуют сложные и дорогие методы  
расшифровки структуры молекул

В конце 1970-х годов был открыт относительно быстрый и дешёвый метод расшифровки последовательности оснований в ДНК



# Последовательность ДНК (пример)

gatcaacactacttgacttcaagacttaccataaagaaaactatagtgtggtattggcaa  
aagacaagacaaatagatcaacataacaaaataaagggccatgaaatagaccatagat  
caattgatttttgacaaagaaggattggcaatagaatgggggtaaagatagtcttctcaac  
aaacggtaccagaatgactgaatacccacatgcaaaaagaaaaagaaatgaacctagaca  
cagatcttatacagttcacaaaaatgtaactcaaatgaatcatagacctaaatataata  
ttcaagactataaaaccctaaaatataacataggggaaaatctaaacaatcttgagtttg  
ttaatgacttttttagatacaataccaaaggcaggatccaggaaagaatcgataagctggg  
cttcattaaaattaaaatatttctgctctatgaagccactgtcaagagaaggaaaaggca  
agccatagactgggagaaaatatttacaanaagacatacatgataaaggactattatccaa  
aatgtacaaagaactctaaaaaacttaacaataagaaaacaaacccaactaaaaactggg  
ccaaagatcttaacagatatattaccaagaagatacacagatggcaaataagcataaaa  
agattaaccacatcatcgtcattaagaaattgcaaattaaaacaacaatgagacaccat  
tatacacctagtagaatgacccaaatccagattactgacataatcaaatgctgacaagga  
tgtggagaaaacaggaactgccattcttggggtgtgggaatgccaaatgggtatgcctgctt  
tggaagacagcttggtggtttcttacaacactaagcatactcttaccaaaagatcgagca

# Для хранения все возрастающей информации о последовательностях ДНК в 1982 году был основан GenBank

**GenBank** — хранилище последовательностей нуклеиновых кислот в виде компьютерных файлов

**Объем GenBank'а:**

**1982:** 680 338 букв в 606 последовательностях

**1992:** 101 008 486 букв в 78 608 последовательностях

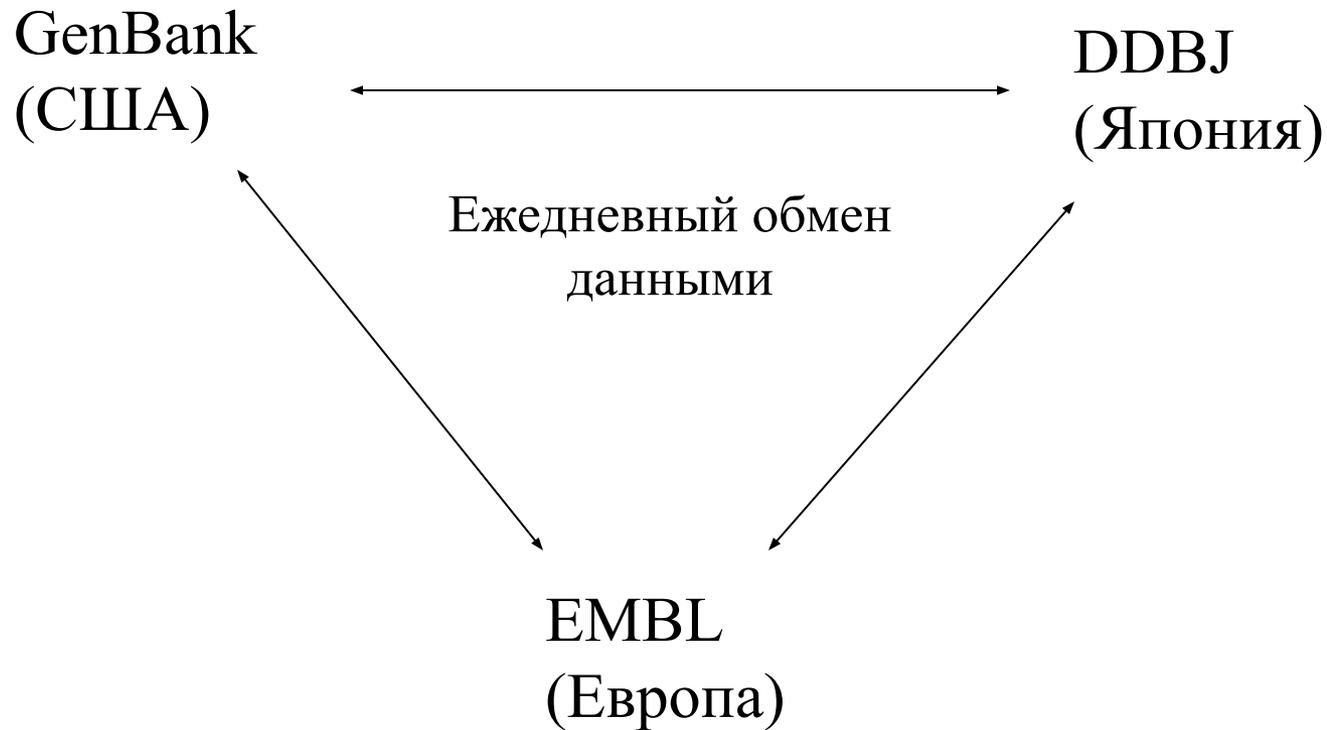
**2002:** 28 507 990 166 букв в 22 318 883 последовательностях

**2004:** 44 575 745 176 букв в 40 604 319 последовательностях

**2005:** 56 037 734 462 букв в 52 016 762 последовательностях  
(из ~165 000 организмов)

Размер файлов — 196 Gb

# International Nucleotide Sequence Database Collaboration



# Структура документа GenBank'a

LOCUS AJ878089 399 bp RNA circular VRL 24-MAY-2005  
DEFINITION Chrysanthemum chlorotic mottle viroid, clone CM298 VR.  
ACCESSION AJ878089  
VERSION AJ878089.1 GI:66571035  
KEYWORDS complete genome; hammerhead ribozyme minus; hammerhead ribozyme plus; RZ+ gene; RZ- gene.  
SOURCE Chrysanthemum chlorotic mottle viroid  
ORGANISM Chrysanthemum chlorotic mottle viroid  
Viroids; Avsunviroidae; Pelamoviroid.  
REFERENCE 1  
AUTHORS Gago,S., de la Pena,M. and Flores,R.  
TITLE A kissing-loop interaction in a hammerhead viroid RNA critical for its in vitro folding and in vivo viability  
JOURNAL Unpublished  
REFERENCE 2 (bases 1 to 399)  
AUTHORS Flores,R.  
TITLE Direct Submission  
JOURNAL Submitted (24-JAN-2005) Flores R., Biologia del Estres, Inst. Biol. Mol. y Cel. de Plantas, Avda. de los Naranjos S/N, Valencia, 46022, SPAIN

FEATURES Location/Qualifiers  
source 1..399  
/organism="Chrysanthemum chlorotic mottle viroid"  
/mol\_type="genomic RNA"  
/specific\_host="Chrysanthemum grandiflora"  
/db\_xref="taxon:68402"  
/clone="CM298 VR"  
/lab\_host="Chrysanthemum grandiflora cultivar Velvet Ridge"  
gene join(392..399,1..53)  
/gene="RZ+"  
misc\_RNA join(392..399,1..53)  
/gene="RZ+"  
/product="hammerhead ribozyme plus"  
misc\_feature join(399,1)  
/gene="RZ+"  
/note="RZ+ self-cleavage site"  
gene complement(51..135)  
/gene="RZ-"  
misc\_RNA complement(51..135)  
/gene="RZ-"  
/product="hammerhead ribozyme minus"  
misc\_feature complement(126..127)  
/gene="RZ-"  
/note="RZ- self-cleavage site"

ORIGIN  
1 ggcacctgac gtcggtgtcc tgatgaagat ccatgacagc atcgaaacct cttccagttt  
61 cggcttgtgc gggagtaaaag ctttcgctct ctccacagcc tcatcaggaa acccacttca  
121 ggtctcgact ggagggctct taaacttccc ctctaagcgg agtagaggta aatacctccg  
181 tcccaccocg ggaggaaaagg ggtggggacc cggaacagct ctagtcccg tcctttggag  
241 tccgtttcta ccggtggaga ttacctccgg gtaagggaga cggggccagc cccagtcggt  
301 tcgctctcgt agtcacagcc gctggggaac ctaggcagat ggctggacgg agtcttagtc  
361 cactccaaag gaccatgggt tttaaaccct catgaggtc

Описание

Последовательность

# GenBank — архивная база данных

## Один эксперимент — один документ

### Зачем в документе GenBank'а описательная часть?

**Ответы:** 1) чтобы пользователь банка мог найти интересующую его последовательность;  
2) для хранения дополнительной информации (откуда ДНК, кто проводил эксперимент по секвенированию, биологическая роль данной последовательности и т.д.)

# Основная проблема больших банков данных — быстрый поиск нужной информации

Для удобства пользования описательная часть документа GenBank разбита на так называемые **поля** (“fields”)

Общий принцип: любая база данных состоит, с одной стороны, из **записей** (или «документов»), а с другой стороны, из **полей**. Каждая запись есть наполнение содержанием нескольких (или всех) полей.

Пример базы данных — телефонная книга.

Записи соответствуют абонентам.

Примеры полей: фамилия, инициалы, адрес, телефон.

# Основная проблема больших банков данных — быстрый поиск нужной информации

Как найти интересующую нас последовательность в GenBank'е?

Существуют специальные компьютерные программы (например, SRS или Entrez), предназначенные для поиска по **ключевым словам** в банках последовательностей.

Пользователь указывает программе, по каким полям нужно искать и какое слово (или слова). Программа выдаёт список записей банка, в которых указанные слова встретились в указанных полях.

# Примеры задания на поиск

- “gene” в поле DEFINITION
- “yeast” в поле ORGANISM
- “Ivanov” в поле AUTHORS
- “yeast” в поле ORGANISM  
И “tRNA” в поле DEFINITION
- “mouse” **ИЛИ** “rat” в поле ORGANISM

# Как искать?

- Перебрать все 52 млн. записей, и в каждой посмотреть, есть ли в соответствующем поле заданное слово.

Это долго даже современному компьютеру!

- Заранее создать **индексную таблицу** каждого из полей и при каждом запросе обращаться к ней

Мораль: при создании программ для работы  
с биологическими базами данных  
необходимо использовать достижения  
**теории алгоритмов**

# Что такое биоинформатика?

---

- Исследование информационных процессов в биологических системах (клетках, органах, организме, популяции).
- Изучение и внедрение в компьютерную науку «биологических» методов анализа информации (нейросетей, генетических алгоритмов, нечеткой логики и др.).
- Применение компьютерных методов для решения биологических задач.
- Телепатия, парапсихология, информационные поля и т.п.



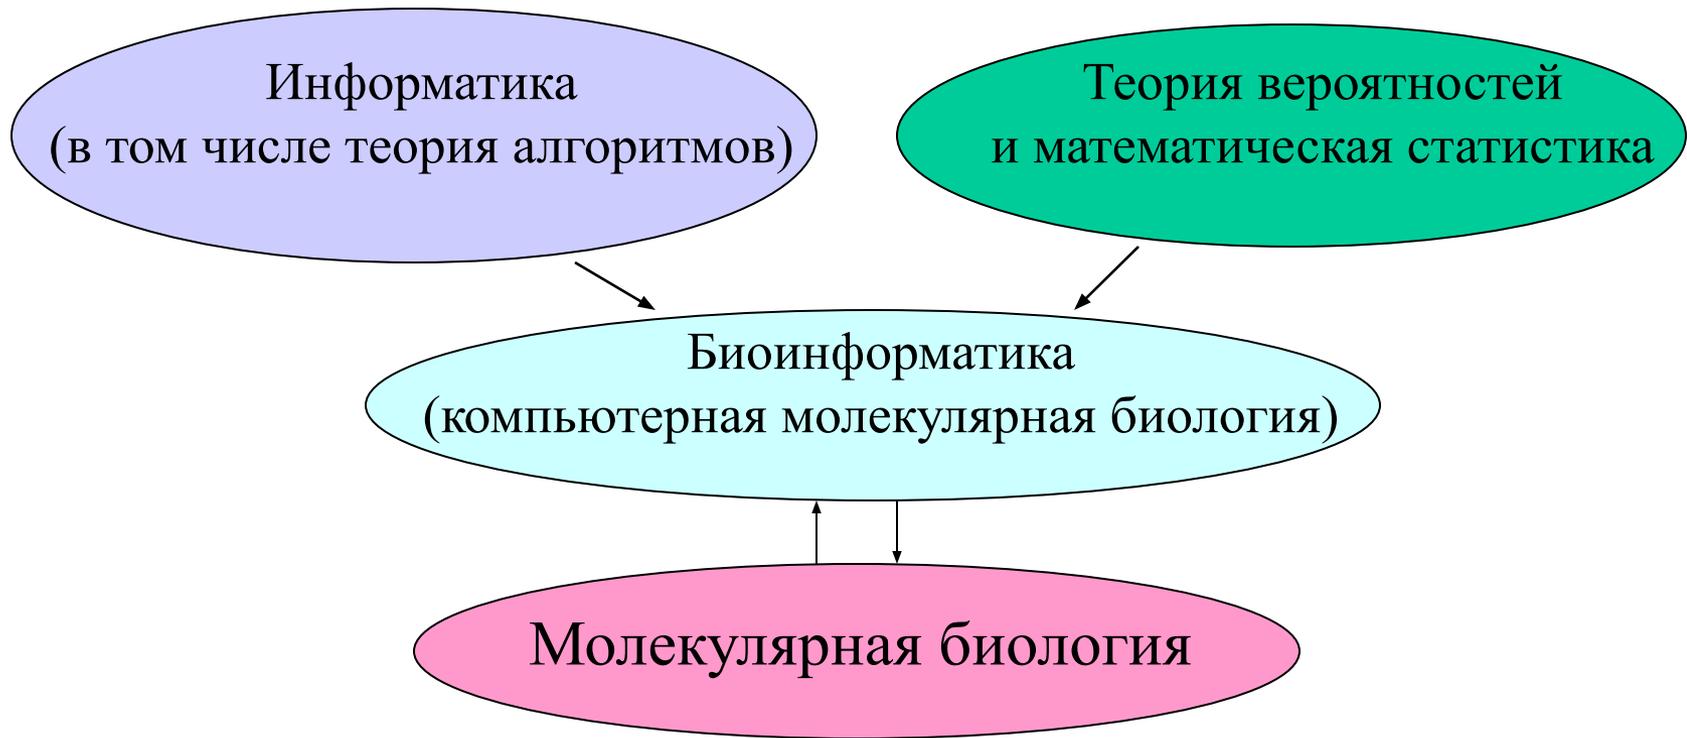
# Что такое биоинформатика?

---

- Исследование информационных процессов в биологических системах (клетках, органах, организме, популяции).
- Изучение и внедрение в компьютерную науку «биологических» методов анализа информации (нейросетей, генетических алгоритмов, нечеткой логики и др.).
- **Применение компьютерных методов для решения биологических задач.**
- Телепатия, парапсихология, информационные поля и т.п.

# Биоинформатика

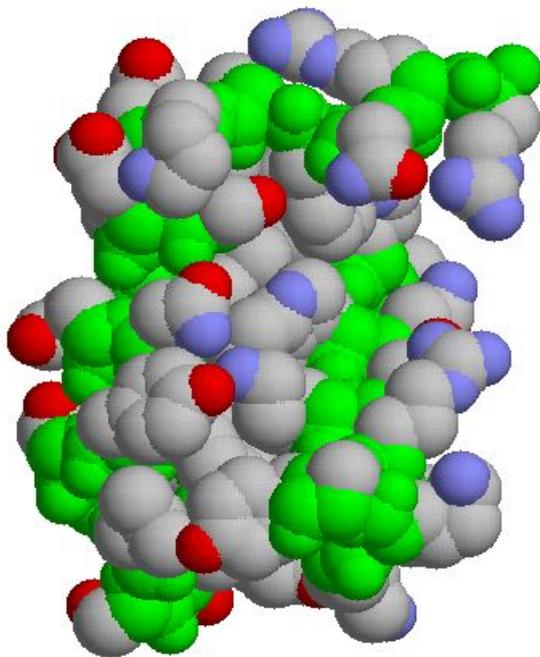
## и её связи с другими дисциплинами



# Основные объекты современной биоинформатики

- Последовательности нуклеиновых кислот
- Последовательности белков
- Пространственные структуры макромолекул (белков, ДНК и РНК) и их комплексов (друг с другом и с малыми молекулами)

# Что такое белок



Пространственная структура

RRNFSKQASE ILNEYFYSHL  
SNPYPSEEAKEELARKCGIT  
VSQVSNWFGN KRIRYKKNI

Последовательность

# Банки структурной биологической информации

