Структурная Биоинформатика

Лекция 10. Базы данных: SCOP, CATH; соревнование CASP

Головин А.В. [1]

[1] МГУ им М.В. Ломоносова, Факультет Биоинженерии и Биоинформатики

Москва, 2012

Содержание

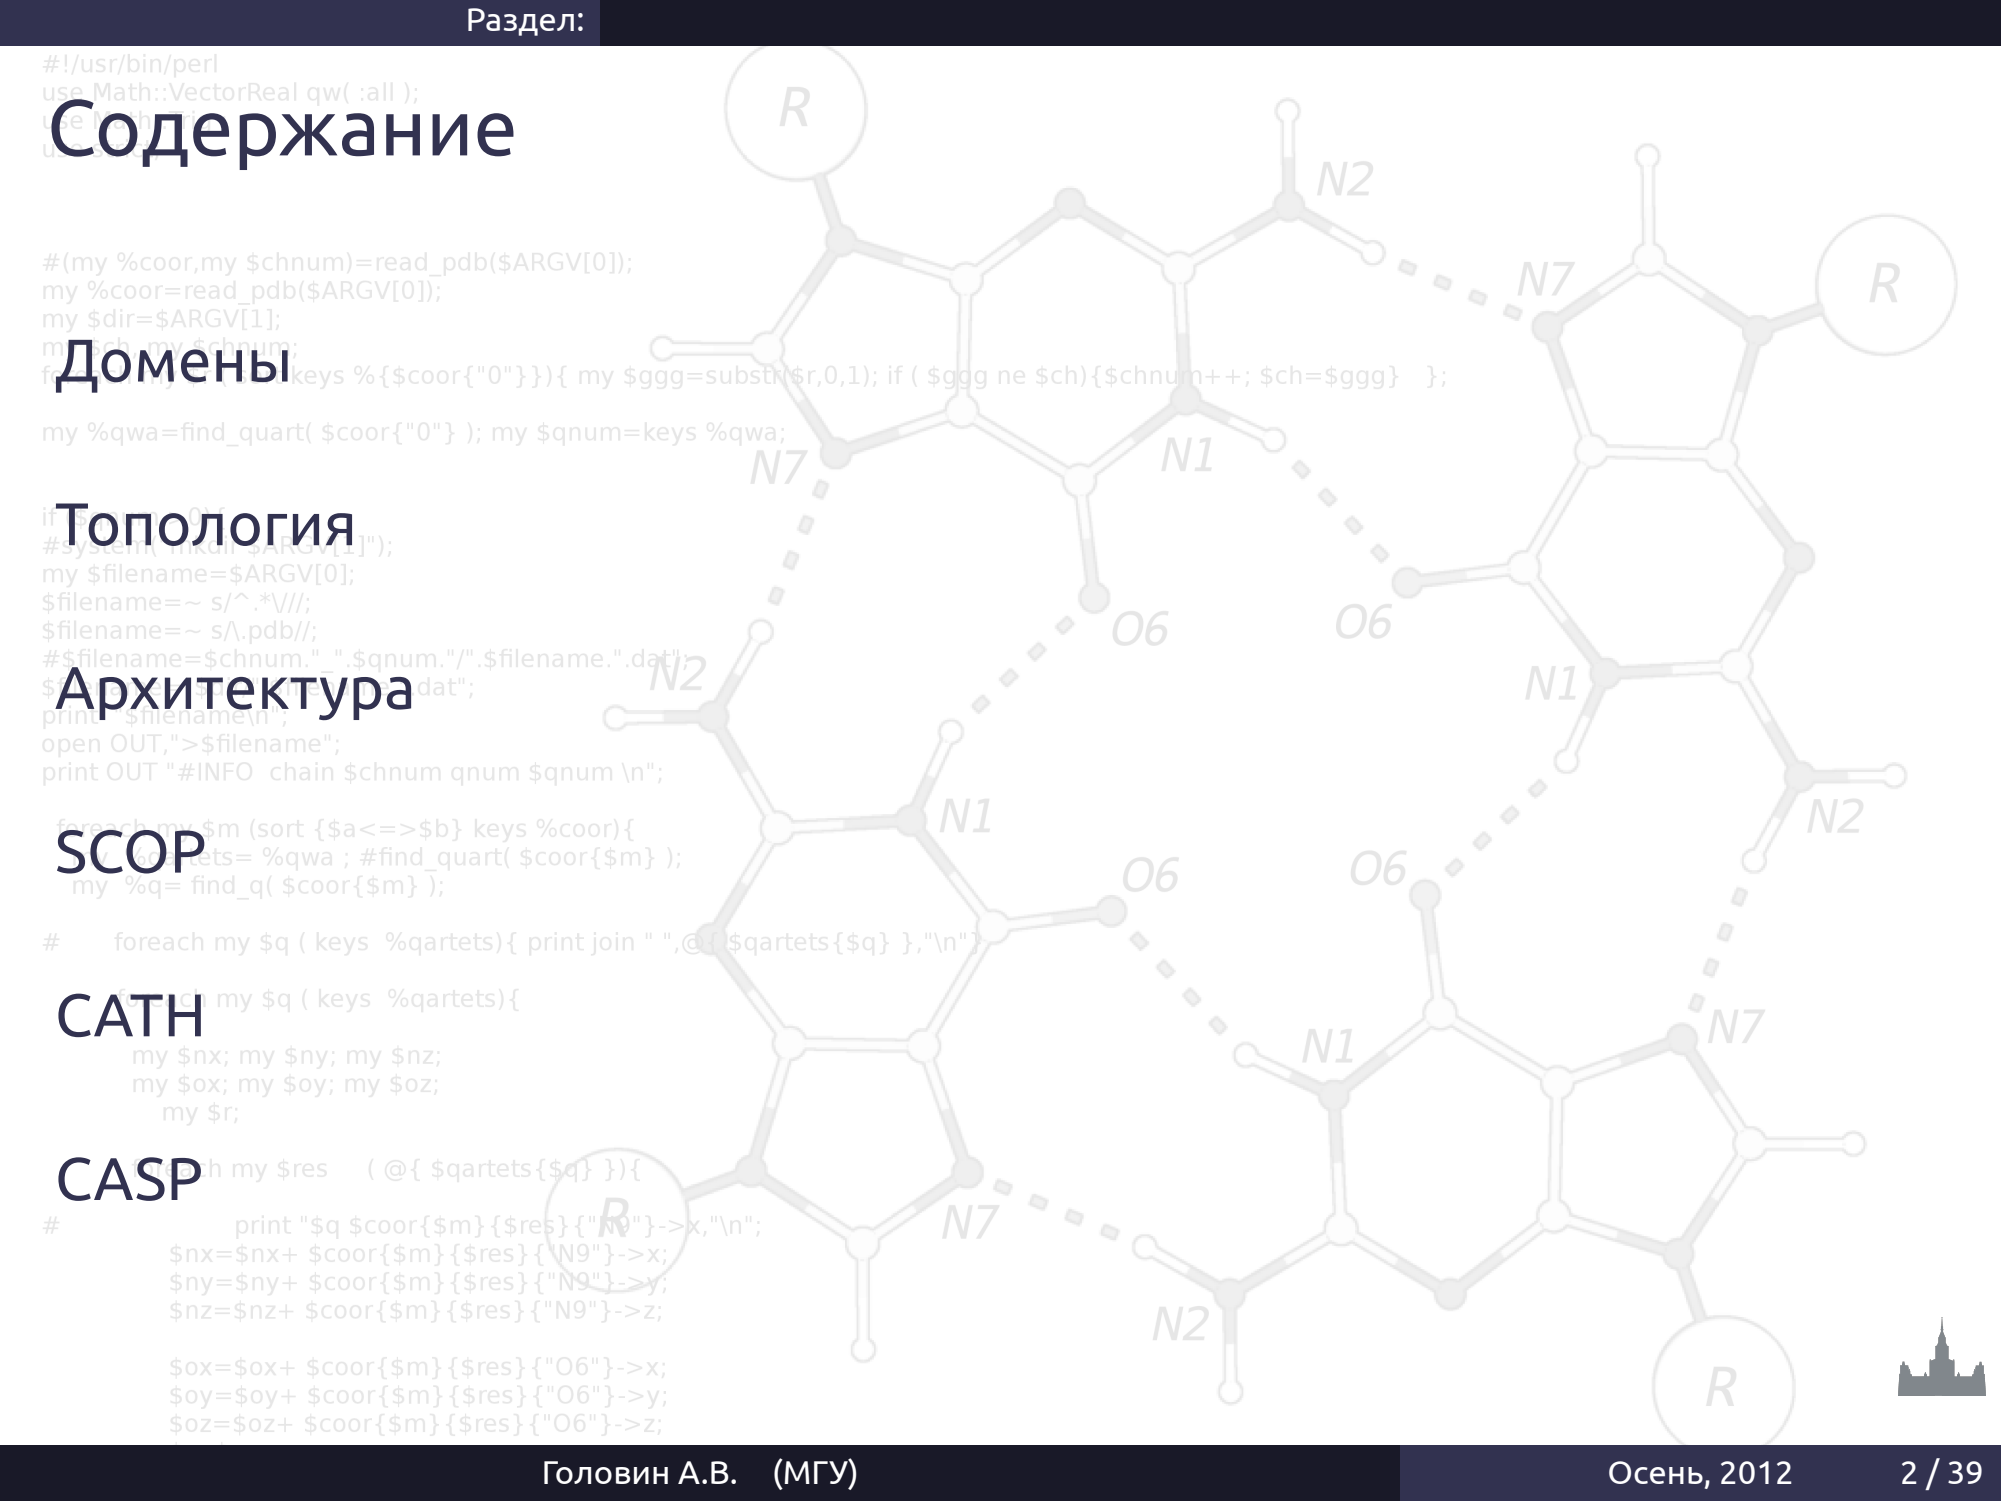

Структурный домен (биоинформатика)

Обособленная в пространстве часть белка, его структурная единица, имеющая:

- сравнительно мало контактов с другими частями белка
- собственное гидрофобное ядро

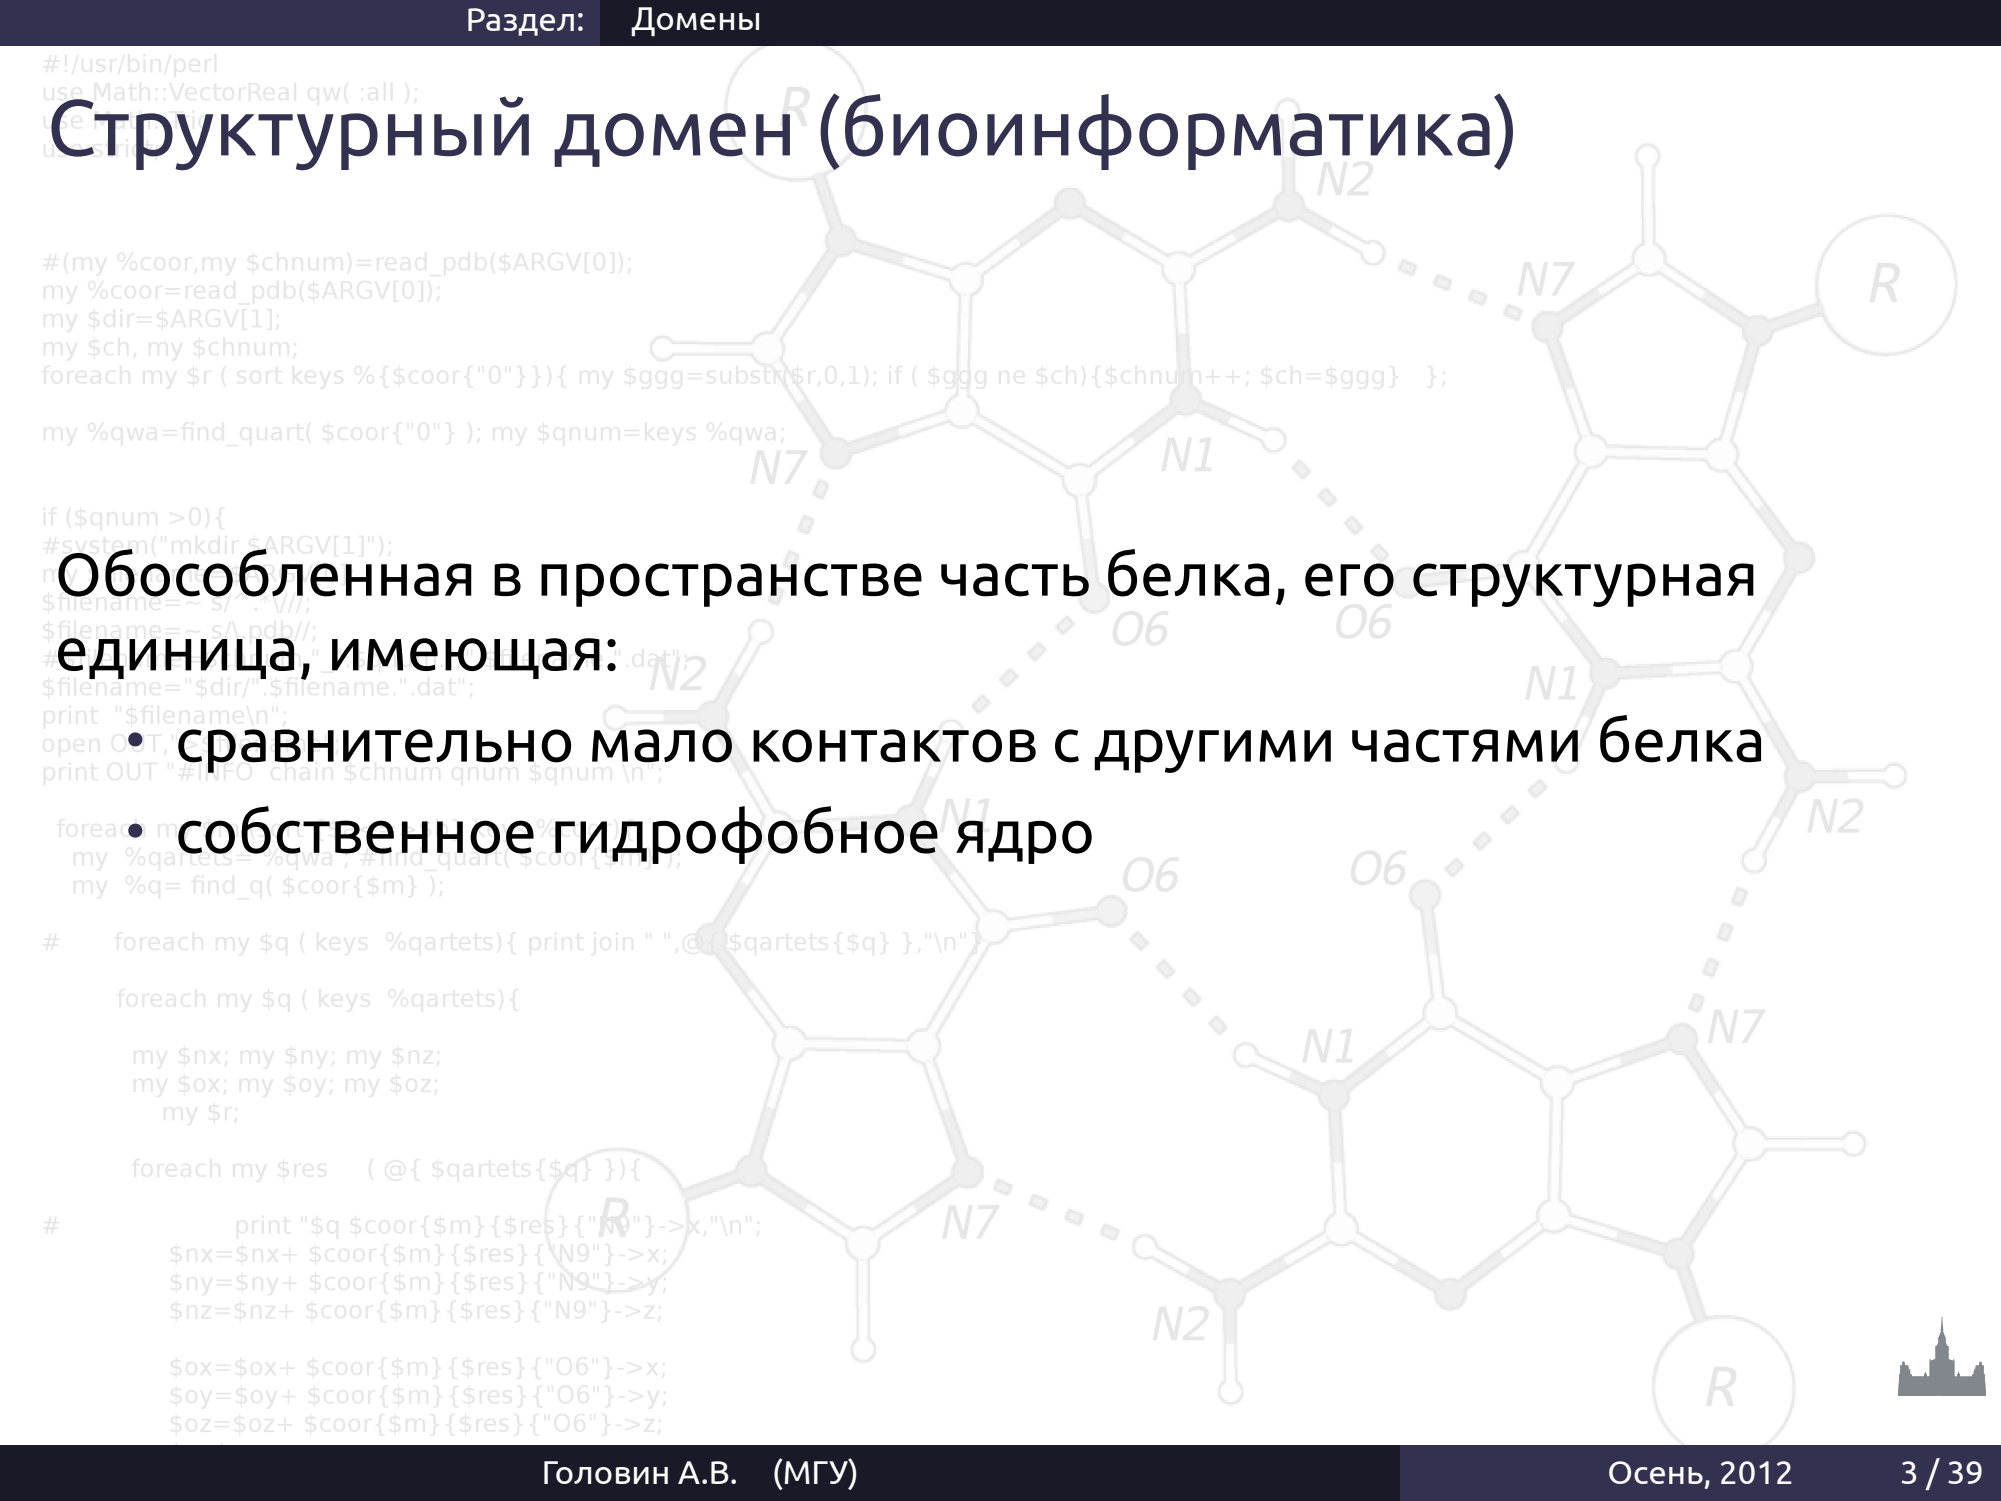

Домен белка XXX (жизнь)

Часть белка, названная доменом:

- Субъективизм
- Образность
- Традиция

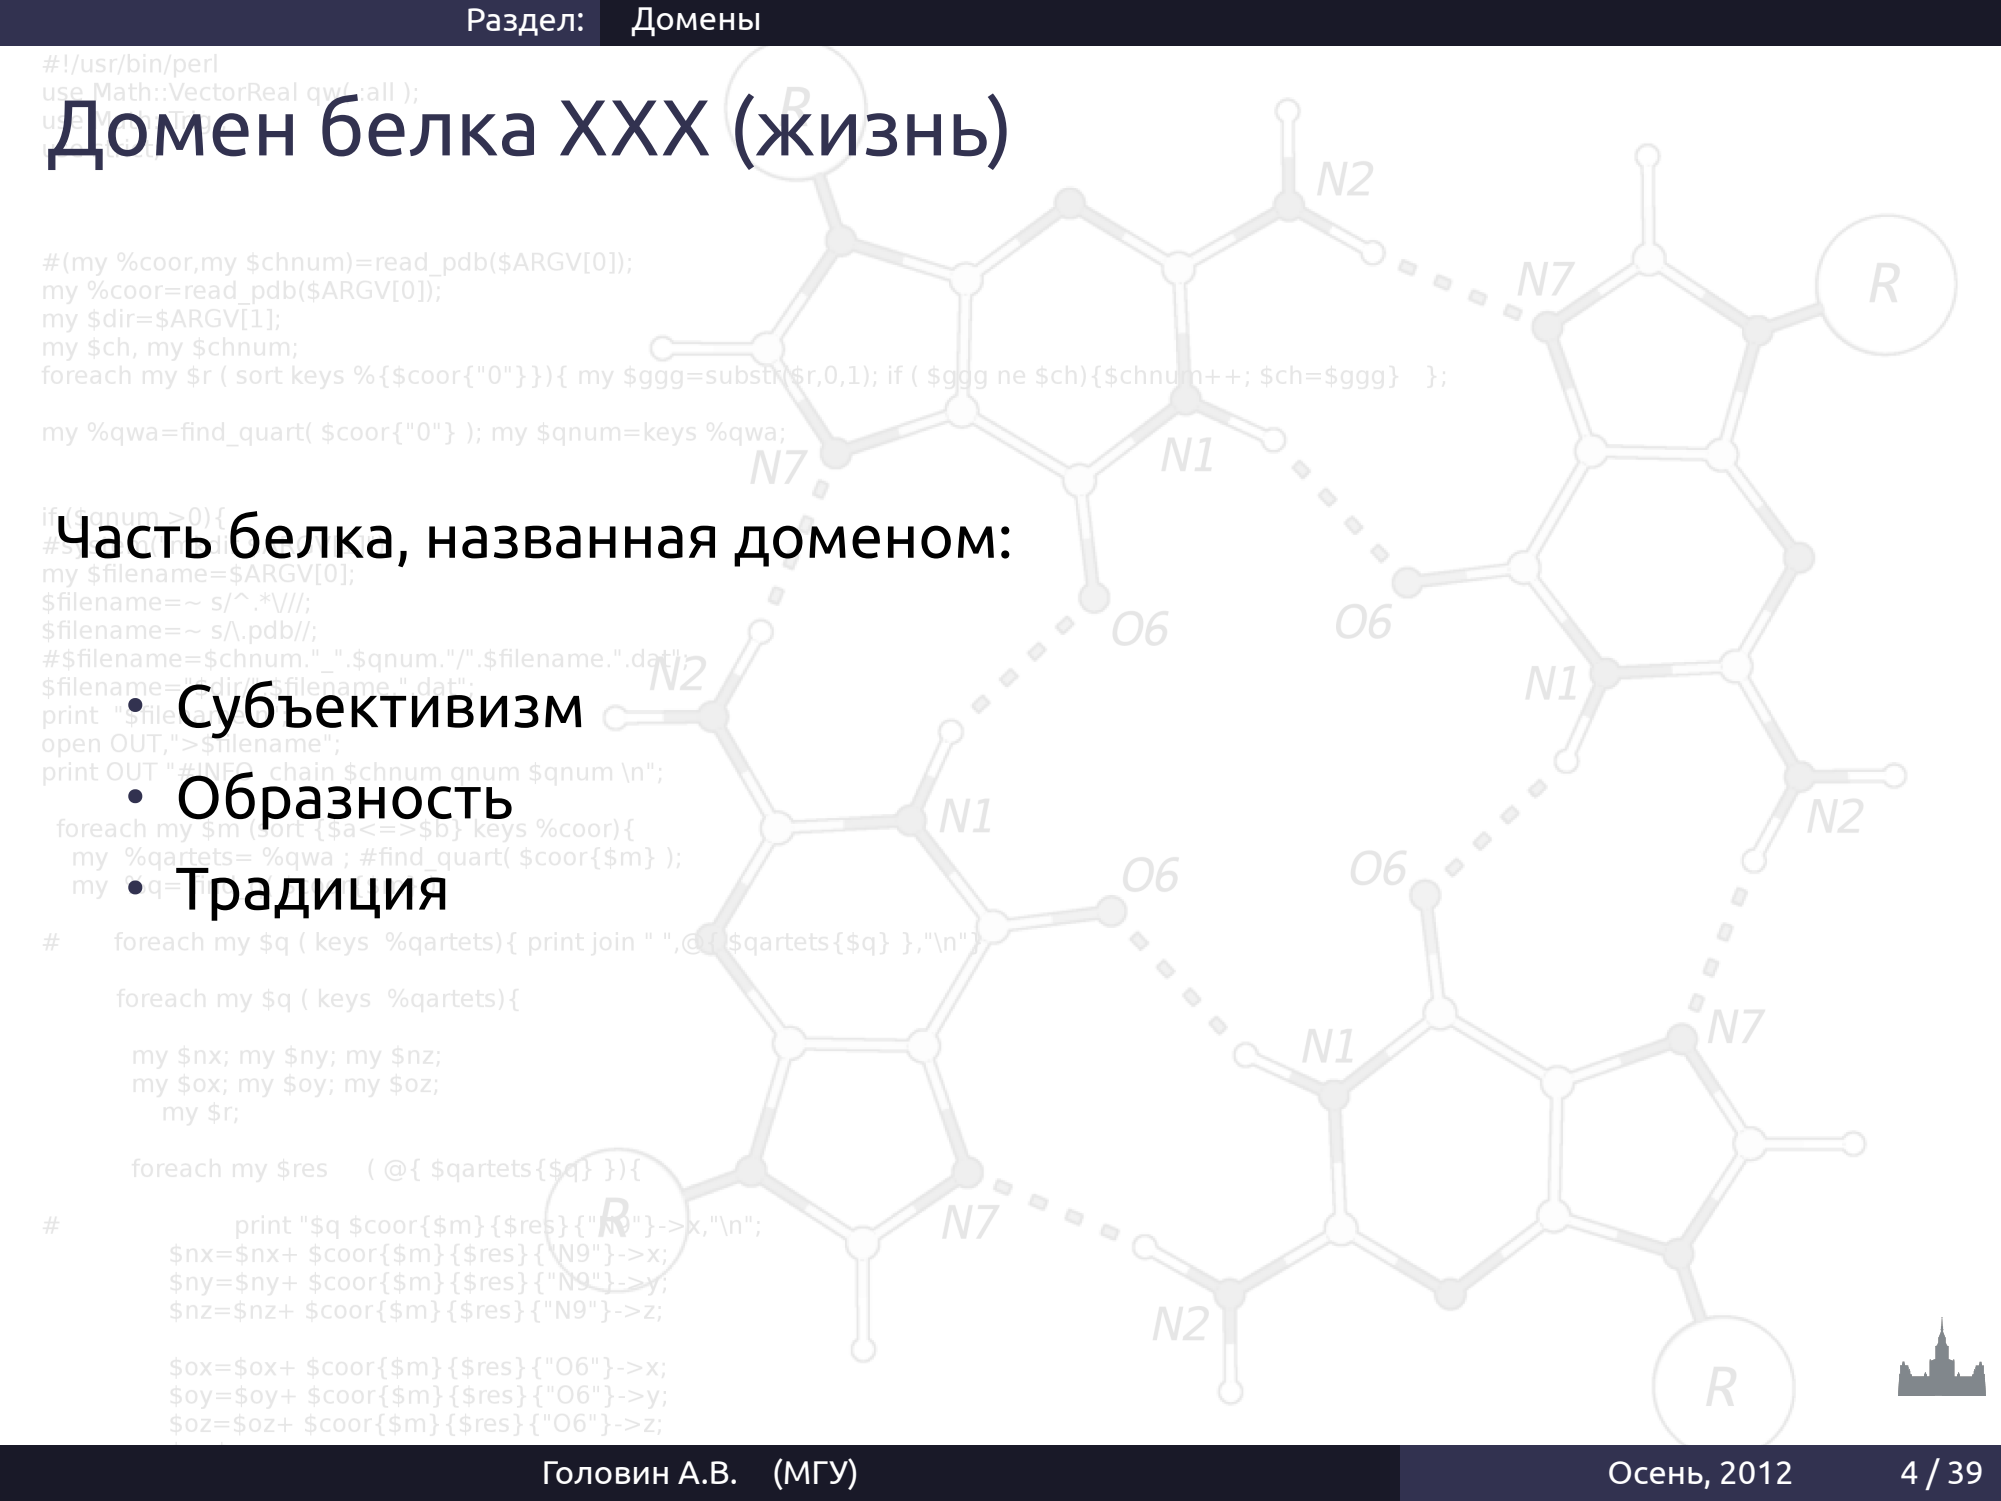

Пример

В полимеразах обычно выделяют три домена: fingers, palm, thumb

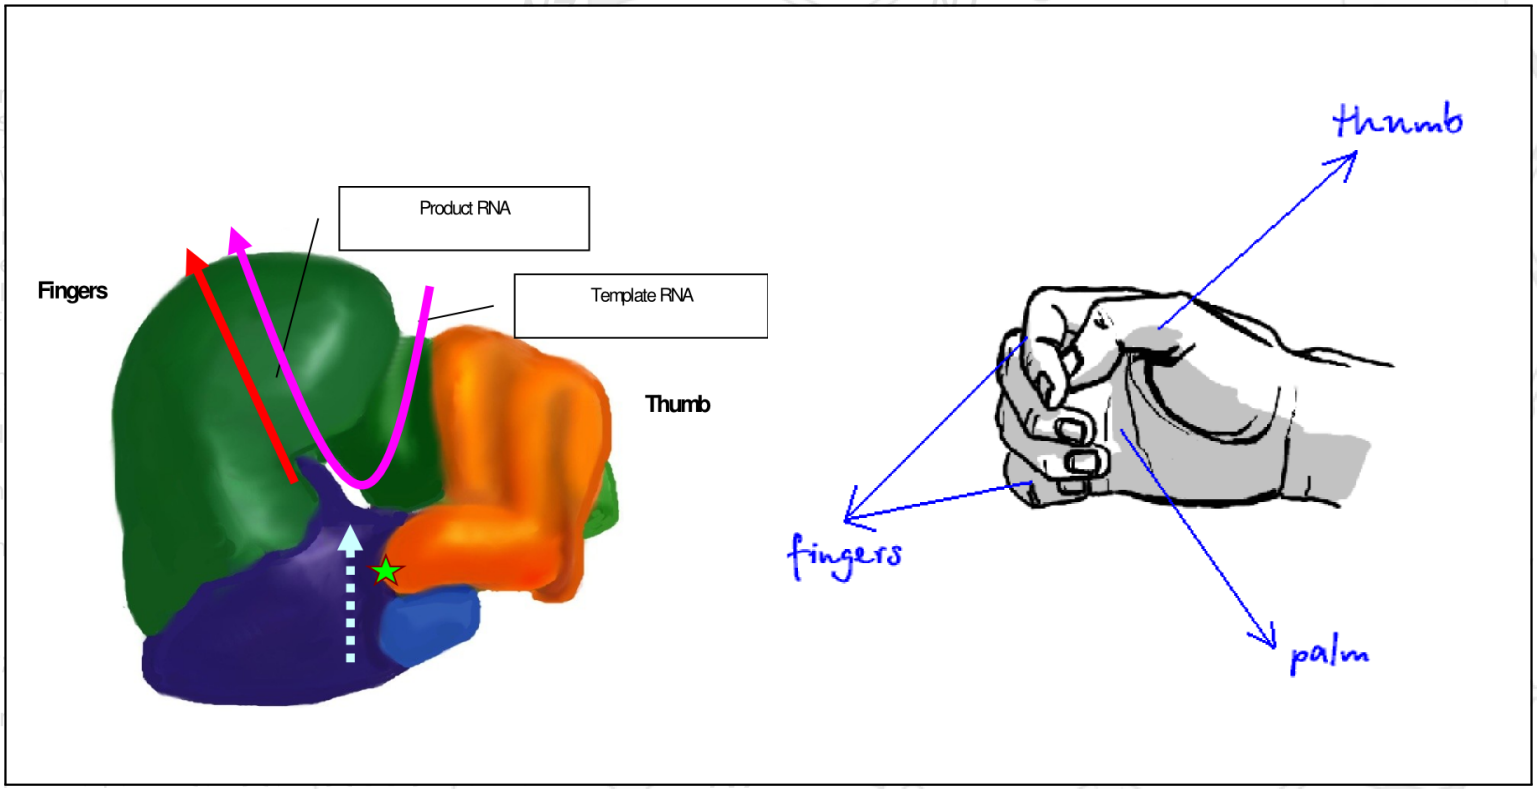

Итог

Три определения доменов часто дают похожие результаты!

Но не всегда

Пример

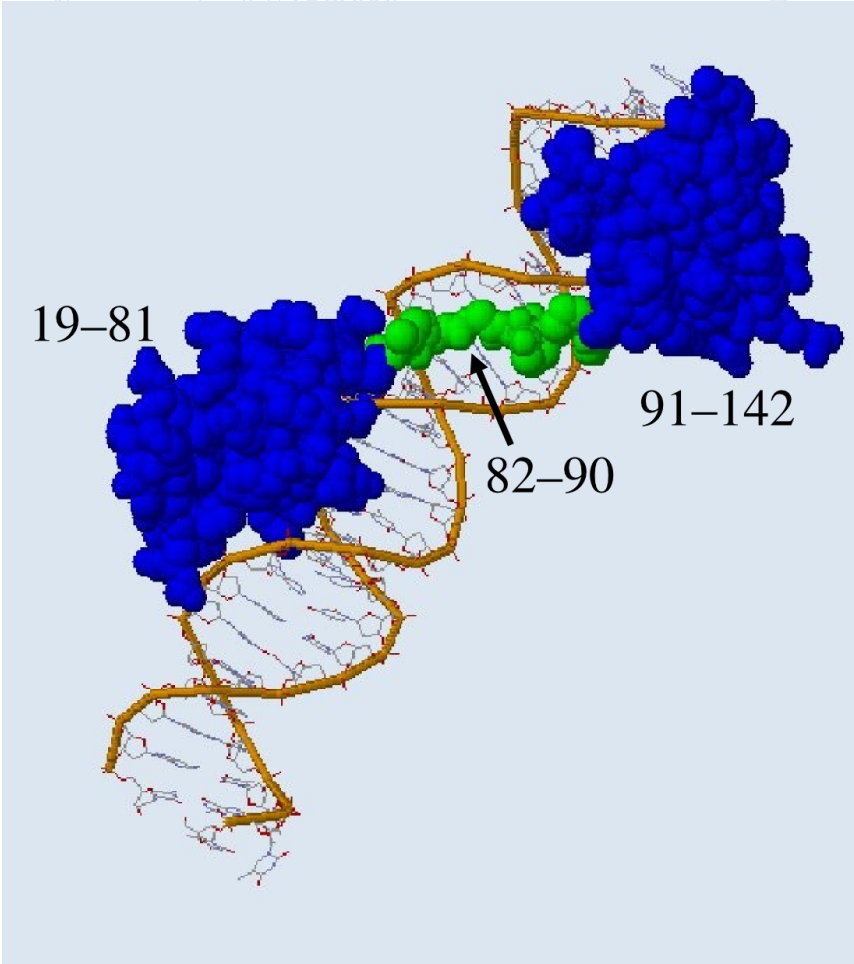

«Парный» (“Paired”) домен из транскрипционного фактора PAX5 человека (PDB 1K78) – очевидно, два структурных домена

Эволюционный домен (PAX в Pfam) включает оба структурных домена (126 а.о.)

Пример

Забавно, что полипептидные цепи обоих структурных доменов имеют общую топологию

- одинаковое число спиралей,
- одинаковые межспиральные взаимодействия,
- одинаковый порядок следования спиралей вдоль цепи;
- * минорные элементы вторичной структуры не в счет!

Структурные домены, Алгоритмы

Основы методов

- Домен имеет собственное гидрофобное ядро (пример: алгоритм DETECTIVE Swindells, 1995)
- Домен – это часть белка, внутри которой много контактов аминокислотных остатков, а между доменами – мало контактов (пример: алгоритм DOMAK, Siddiqui&Barton, 1995)

Siddiqui &Barton, 1995: DOMAK

Сверху – вниз, от целого – к части!

- Предпосылки: домен состоит из одного или двух непрерывных участков полипептидной цепи
- Число контактов между остатками внутри домена больше, чем число междоменных контактов

Формализация

- Два остатка контактируют, если расстояние между ними меньше 5Å
- Если белок разбит на две части, A и B, то определяется индекс разделенности:

$$SplitValue = (\frac{int_A}{ext_{AB}})(\frac{int_B}{ext_{AB}})$$

  - int_A число пар контактирующих остатков из A;
  - int_B число пар контактирующих остатков из B;
  - int_{AB} число пар контактирующих остатков, один из A, а другой – из B

Пример

Структура 1CD4. Часть A: N-конец полипептидной цепи до остатка i; часть B – от (i+1) до C-конца

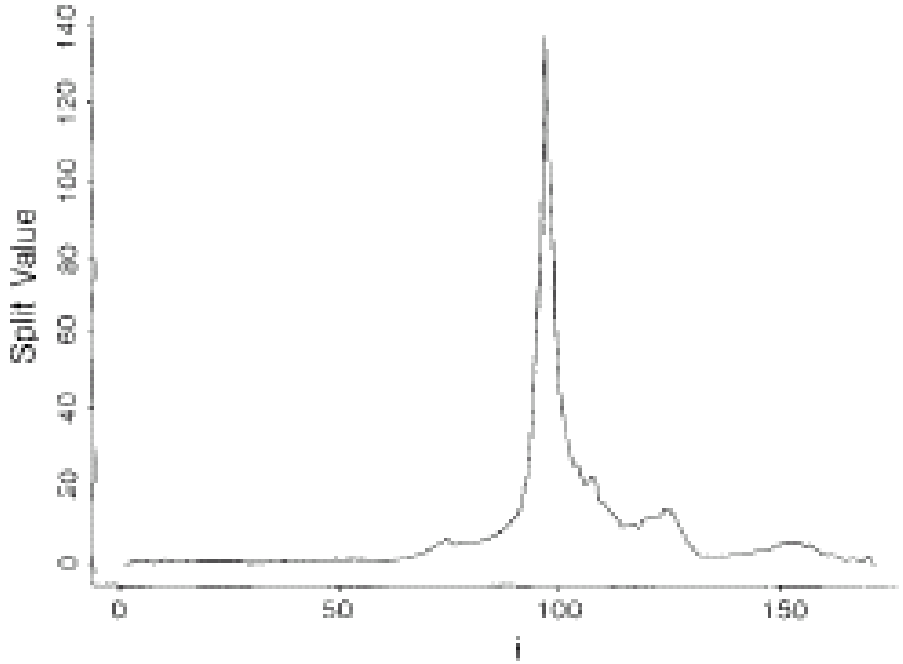

График зависимости индекса разделенности от номера граничного остатка

Алгоритм

- К полной цепи применяются 2 метода (целый или сегментный домен). Выбирается разделение с лучшим индексом
- К полученным двум доменам применяется та же процедура. В случае, когда домен состоит из двух сегментов, применяется также дополнительный метод.
- Алгоритм останавливается в зависимости от пороговых значений:
  - MDS – минимальный размер домена (в числе остатков)
  - MSS – минимальный размер сегмента
- Отдельная процедура предусмотрена для сегментов, длина которых между MDS и MSS
- Найденные домены проверяются на “компактность”; некомпактные – сливаются в один

Swindells, 1995 DETECTIVE

Снизу – вверх, наращивание частей!

Предпосылка: каждый домен имеет свое гидрофобное ядро.

Этапы:

- выявление гидрофобных ядер в структуре
- «натягивание» доменов на гидрофобные ядра

Подробности

- Отбираются остатки, которые
  - Слабо экспонированы (<7%)
  - Принадлежат спиралям или тяжам
  - Более 75% контактов их атомов с другими атомами классифицируются как гидрофобные
  - Контактом считается сближение “тяжелых” атомов на сумму vdW радиусов + 1Å
  - Гидрофобным контактом считается контакт углеродов
- Два остатка из отобранных считаются взаимодействующими гидрофобно, если число гидрофобных межатомных контактов превосходит число негидрофобных межатомных контактов

Подробности

Строится граф:

- Вершина – отобранный остаток
- Ребро соединяет вершины, если соответствующие остатки гидрофобно взаимодействуют
- Связные компоненты графа, содержащие 5 или более остатков, называются гидрофобными ядрами

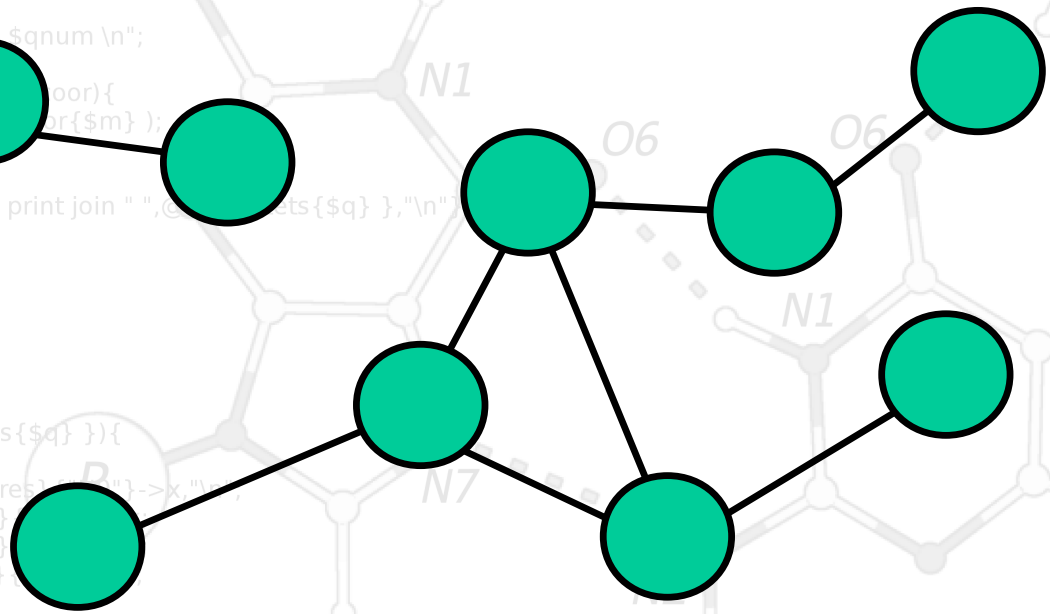

Всё сложнее

Гидрофобные ядра – еще не домены!

Для получения доменов применяется много ходовая процедура чистки-слияния

Топология

Это описание последовательности элементов вторичной структуры и их взаимного расположения в пространстве.

Белки имеют одинаковую топологию если **основные** элементы вторичной структуры расположены в последовательности в одном и том же порядке и взаимное расположение этих элементов в пространстве сходно.

Термины “укладка” (folding) и “топология” (topology) обычно трактуются как синонимы

Пример

Каталаза (C-концевой домен)

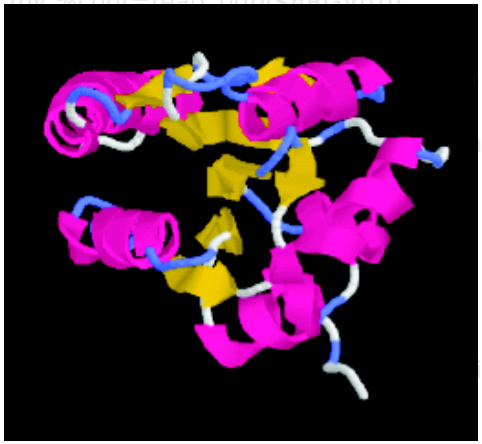

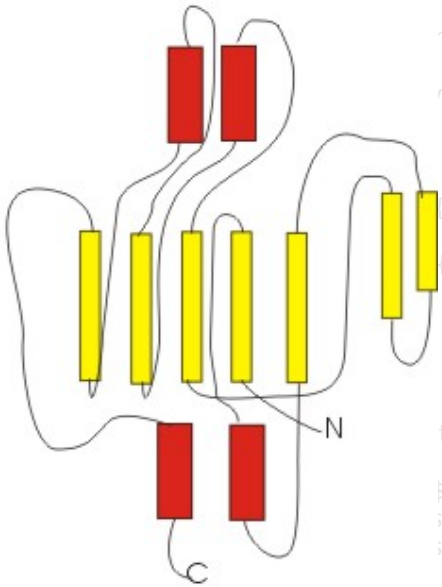

Флаводоксин

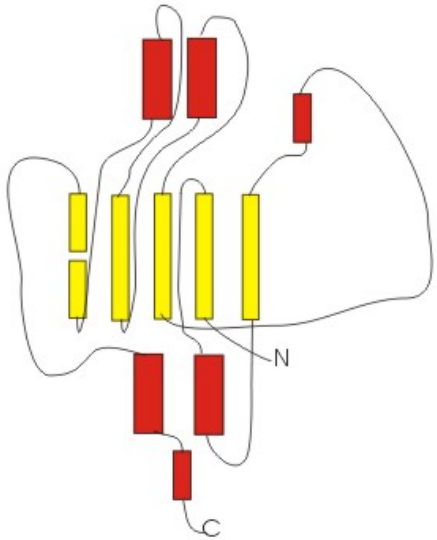

Архитектура

это описание взаимного расположения в пространстве элементов вторичной структуры без учета их последовательности в полипептидной цепи

Т.о., белки с одинаковой топологией (укладкой) имеют одинаковую архитектуру, по определению.

Обратное не верно!

Пример

Архитектура – пучок 4x параллельных спиралей

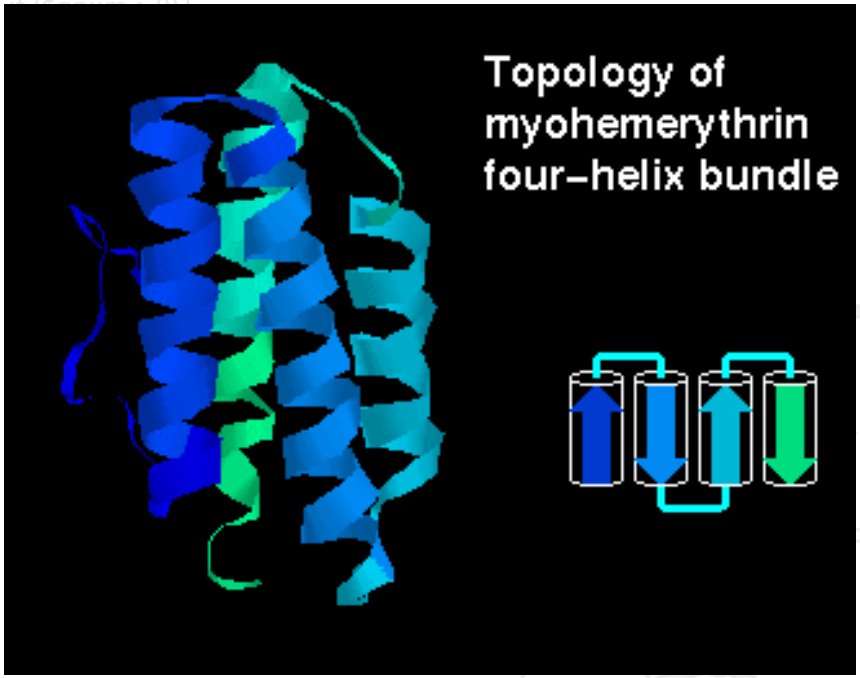

Топология пучка параллельных спиралей может быть отражена диаграммой TOPS

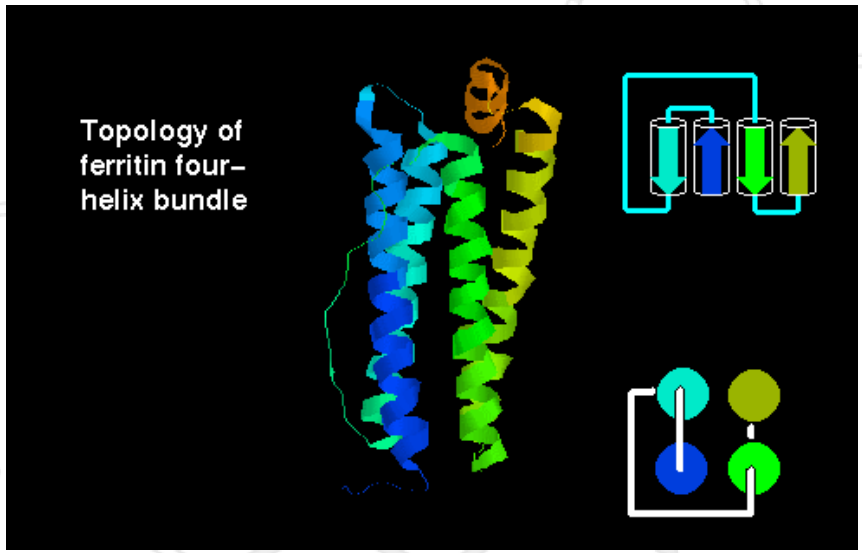

Недостаток

К сожалению, на сегодня отсутствуют адекватные универсальные способы описания топологии … Поэтому остается большой произвол в трактовке того, какие топологии встречаются в белках, сколько разных топологий и т.п.

В отличие от сравнительной однозначности в трактовке элементов вторичной структуры разными авторами и программами!

Примеры описания топологии. TOPS

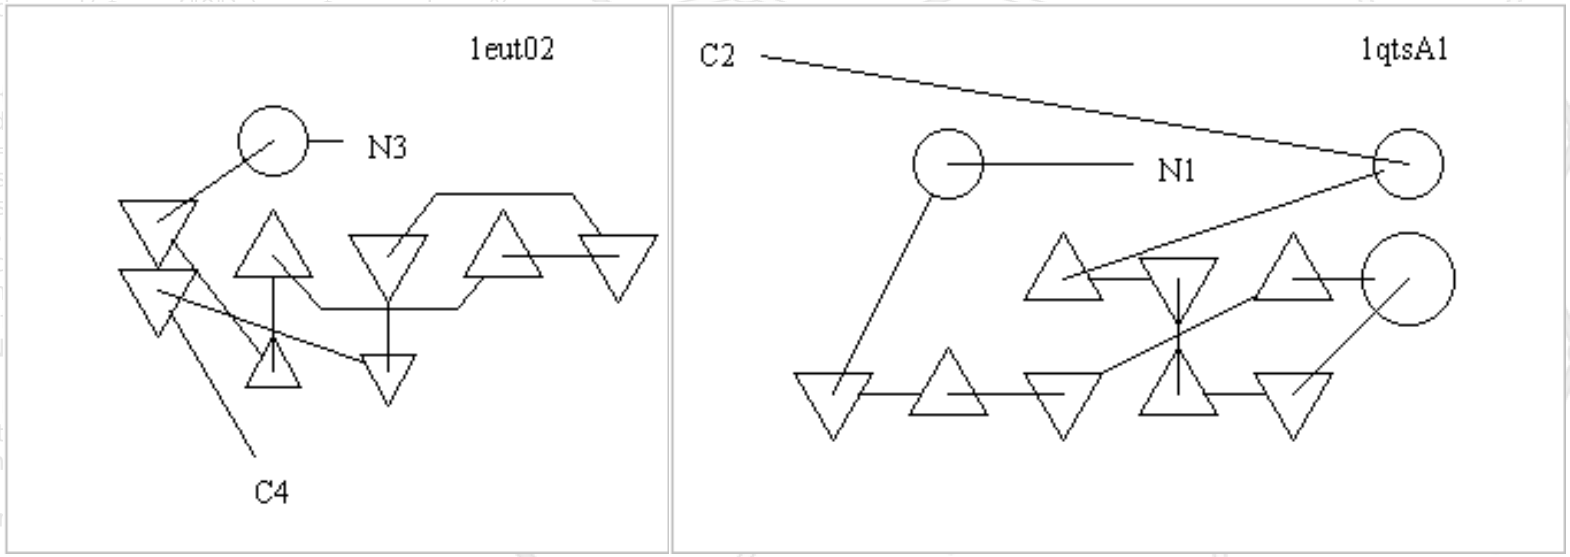

На самом деле, у этих белков сходная топология

Примеры, частые в глобулярных белках

- Бета-сэндвич (sandwich)
- Бета-баррель (barrel)
- Рулет (jelly roll) – по существу, сэндвич, содержащий мотив “рулет”
- Бета-спираль (beta-helix)
- 3х (4х) спиральный узел (3helical bundle)
- Пучек спиралей (parrallel helical bundles)
- Спирализованная спираль
- Бета-цилиндр (TIM barrel)
- Укладка Россмана (Rossman fold)

Классификации структурных доменов

- SCOP (Murzin, Benner, Hubbard, Chotia, 1995)
- CATH (Orengo et al., 1993, 1997)
- FSSP (Holm&Sander, 1993)
- другие

Structural Classification of Proteins, SCOP

- Экспертное выделение доменов
- Экспертная классификация

Уровни классификации в SCOP

- Класс
- Укладка (fold) – сходная топология
- Суперсемейство – структурная гомология (?)
- Семейство – сходство последовательностей и/или хорошее пространственной выравнивание цепей
- Белок – б.м. ортологичные белковые домены
- Вид – конкретный белок

Классы

Основные

- Альфа-спиральные домены (218 укладок)
- Бета-структурные домены (144)
- Альфа/бета структурные домены (a/b) (136)
  - (бета-альфа-бета структурные единицы)
- Альфа+бета домены (a+b) (279)
- (разделенные альфа спиральные и бета-структурные области)

Классы

Специфические

- Многодоменные белки (46)
- (сложные домены)
- Мембранные (47)
- (кроме белков иммунной системы)
- Маленькие (75)

Формально собранные классы

- Спирализованные спирали (6)
- Низкое разрешение (24)
- Пептиды, фрагменты (116)
- Искусственные белки (42)

Scop Classification Statistics. 1.73 release

34 494 PDB Entries (Sep 2007). 97 178 Domains

Class	Number of folds	Number of superfamilies	Number of families
All alpha proteins	259	459	772
All beta proteins	165	331	679
Alpha and beta proteins (a/b)	141	232	736
Alpha and beta proteins (a+b)	334	448	897
Multi-domain proteins	53	53	74
Membrane and cell surface proteins	50	92	104
Small proteins	85	122	202

Class Architecture Topology Homologous superfamily, CATH

- Белок делится на домены автоматически при согласованных результатах трех алгоритмов:
  - DETECTIVE (Swindells, 1995),
  - PUU (Holm & Sander, 1994)
  - DOMAK (Siddiqui and Barton, 1995).
- При несовпадении результатов алгоритмов – решение о доменах за экспертом

CATH: уровни классификации

- Класс: основные all-alpha, all-beta, alpha-beta
- Архитектура: сходное пространственное расположение элементов вторичной структуры без учета их
- последовательности
- Топология (укладка): сходное взаимное расположение вдоль цепи и в пространстве элементов вторичной структуры
- Суперсемейство: предположительно или несомненно гомологичные домены
- Семейство: сходные последовательности (>35% identity и выровненные участки покрывают >60% длины)

Внимание

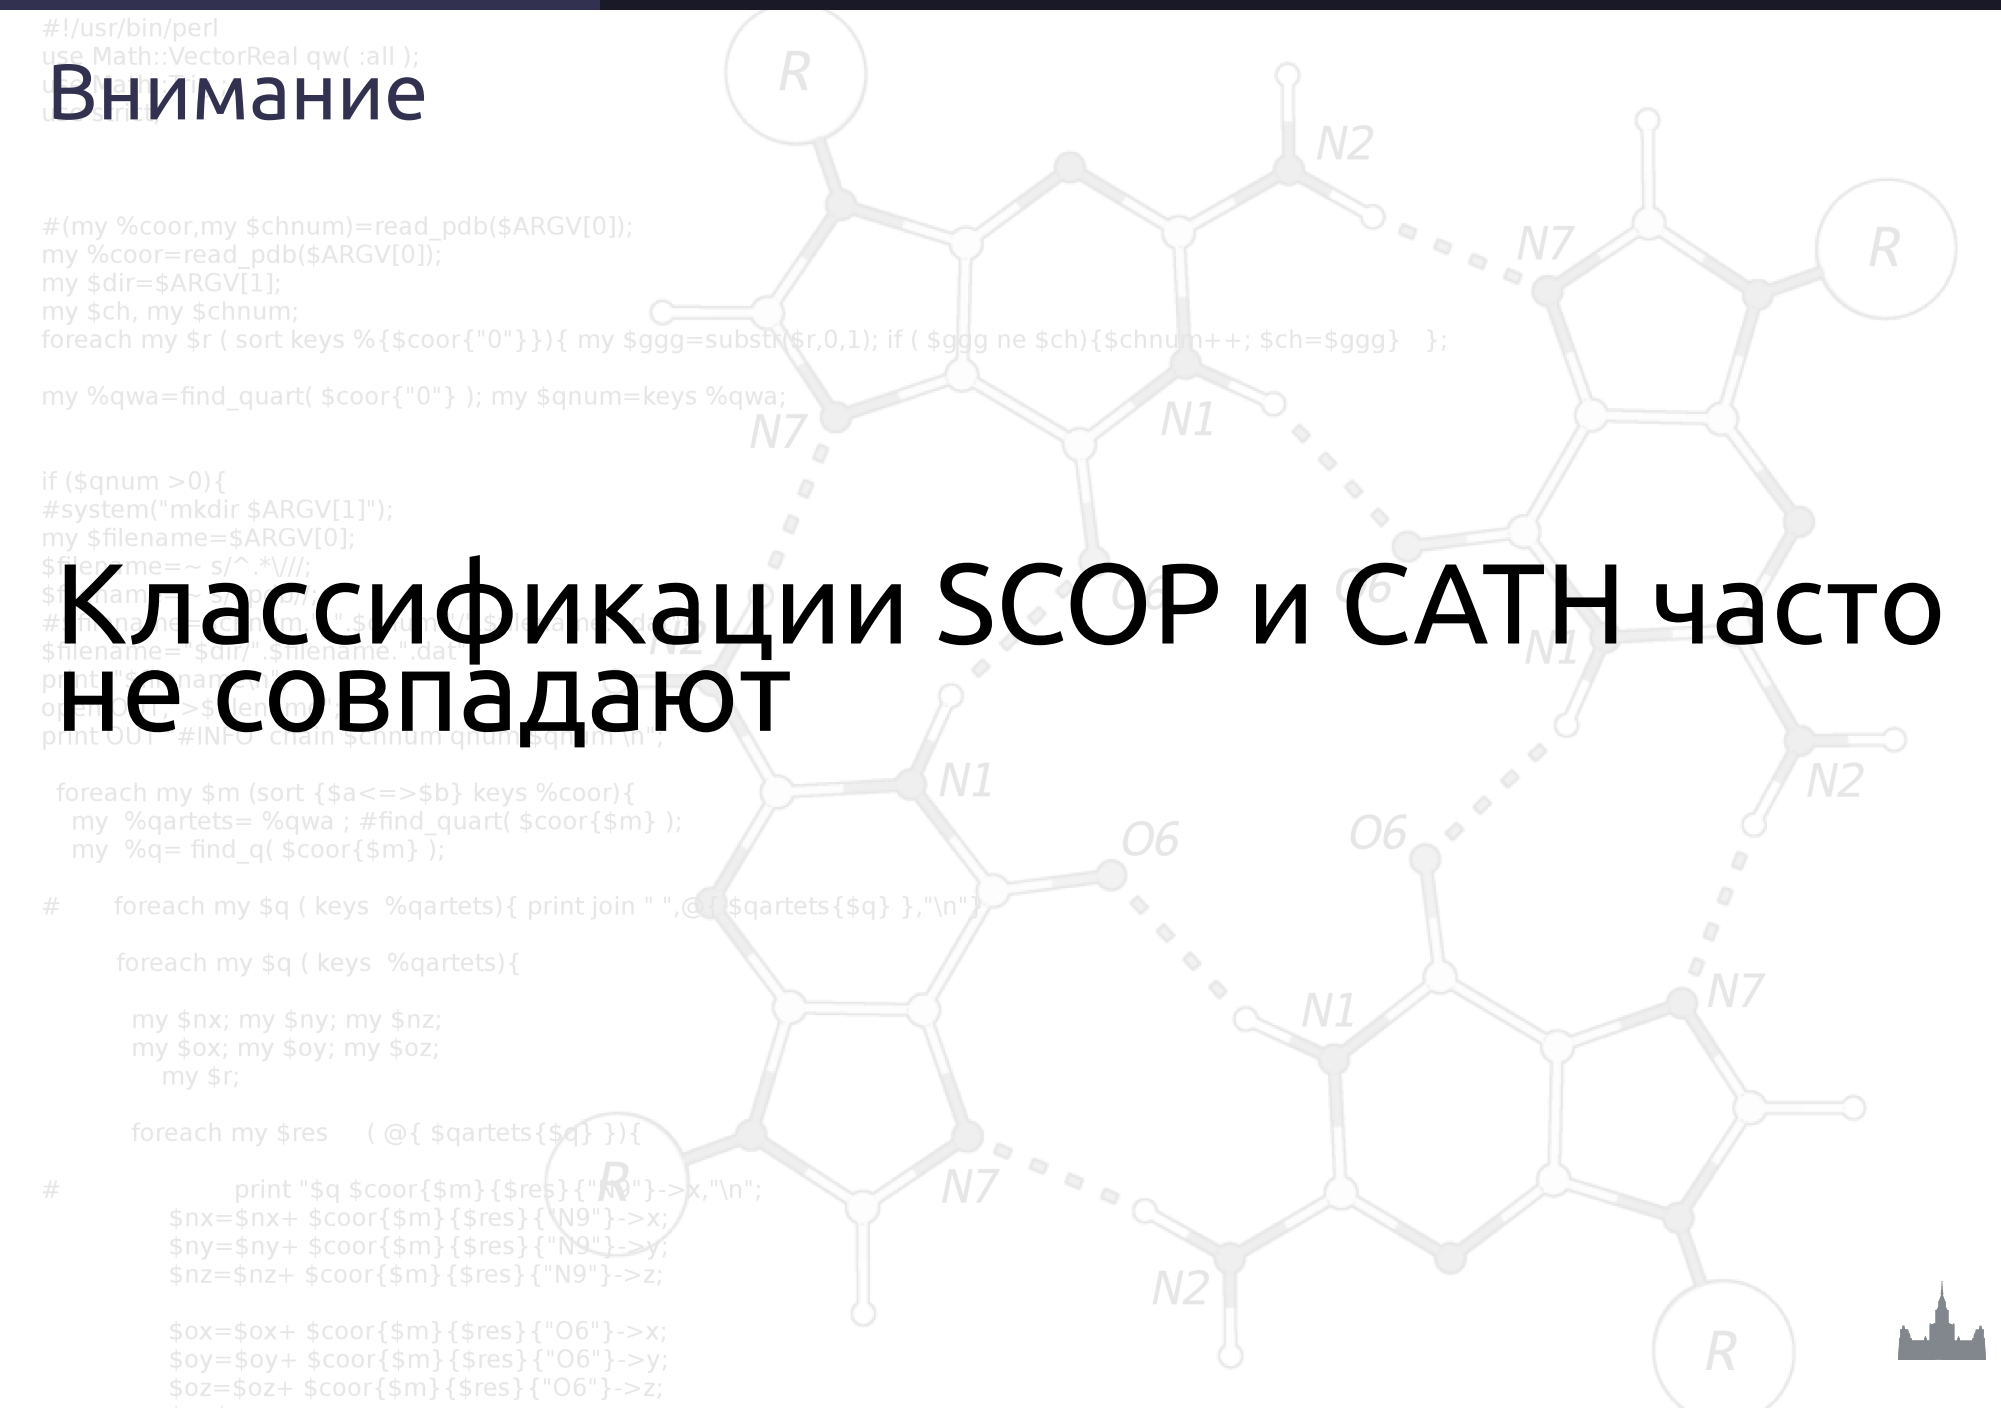

Классификации SCOP и CATH часто не совпадают

CASP

CASP - Critical Assessment of Techniques for Protein Structure Prediction

или соревнование между различными группами по предсказанию структуры белка, это происходит раз в два года начиная с 1994 (http://predictioncenter.org/).

Основная задача этого явления это выявление возможностей современных методов предсказания структуры. Для соревнования выдаётся последовательность белка, для которого известна структура, но не опубликована.

Цели CASP

В CASP7 решались следующие вопросы:

- Насколько модели похожи на экспериментальную структуру?
- Насколько верно выравнивание?
- Были ли ранее решены подобные структуры?
- Насколько гомологичное моделирование улучшает структуру, по сравнению с копированием?
- Есть ли прогресс по сравнению с предыдущими соревнованиями?
- Какие методы самые эффективные?

Категории CASP

Результаты сравнивались в следующих категориях:

- 3D структура (все CASPs)
  - Гомологичное моделирование
  - Распознавание укладки.
  - de novo предсказание.
- 2D структура (прекратили после CASP5)
- Предсказание структуры комплексов (CAPRI)
- Предсказание контактов (с CASP4)
- Предсказание неструктурированных областей (с CASP5)
- Предсказание границ домена (с CASP6)
- Предсказание функции (с CASP6)
- Определение качества модели (с CASP7)
- Улучшение модели (с CASP7)

Визуализация CASP

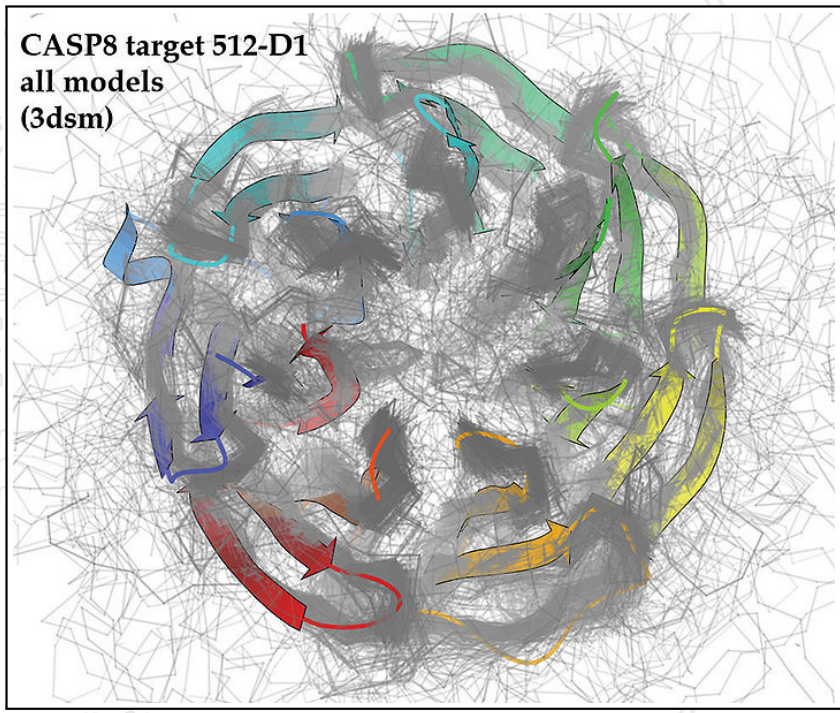

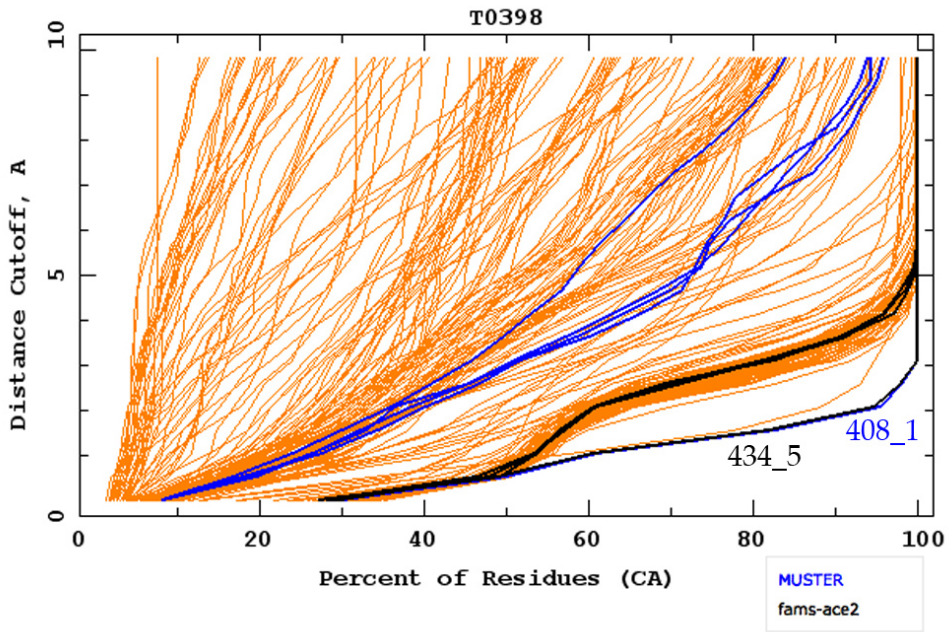

Поиск ядра метилаз

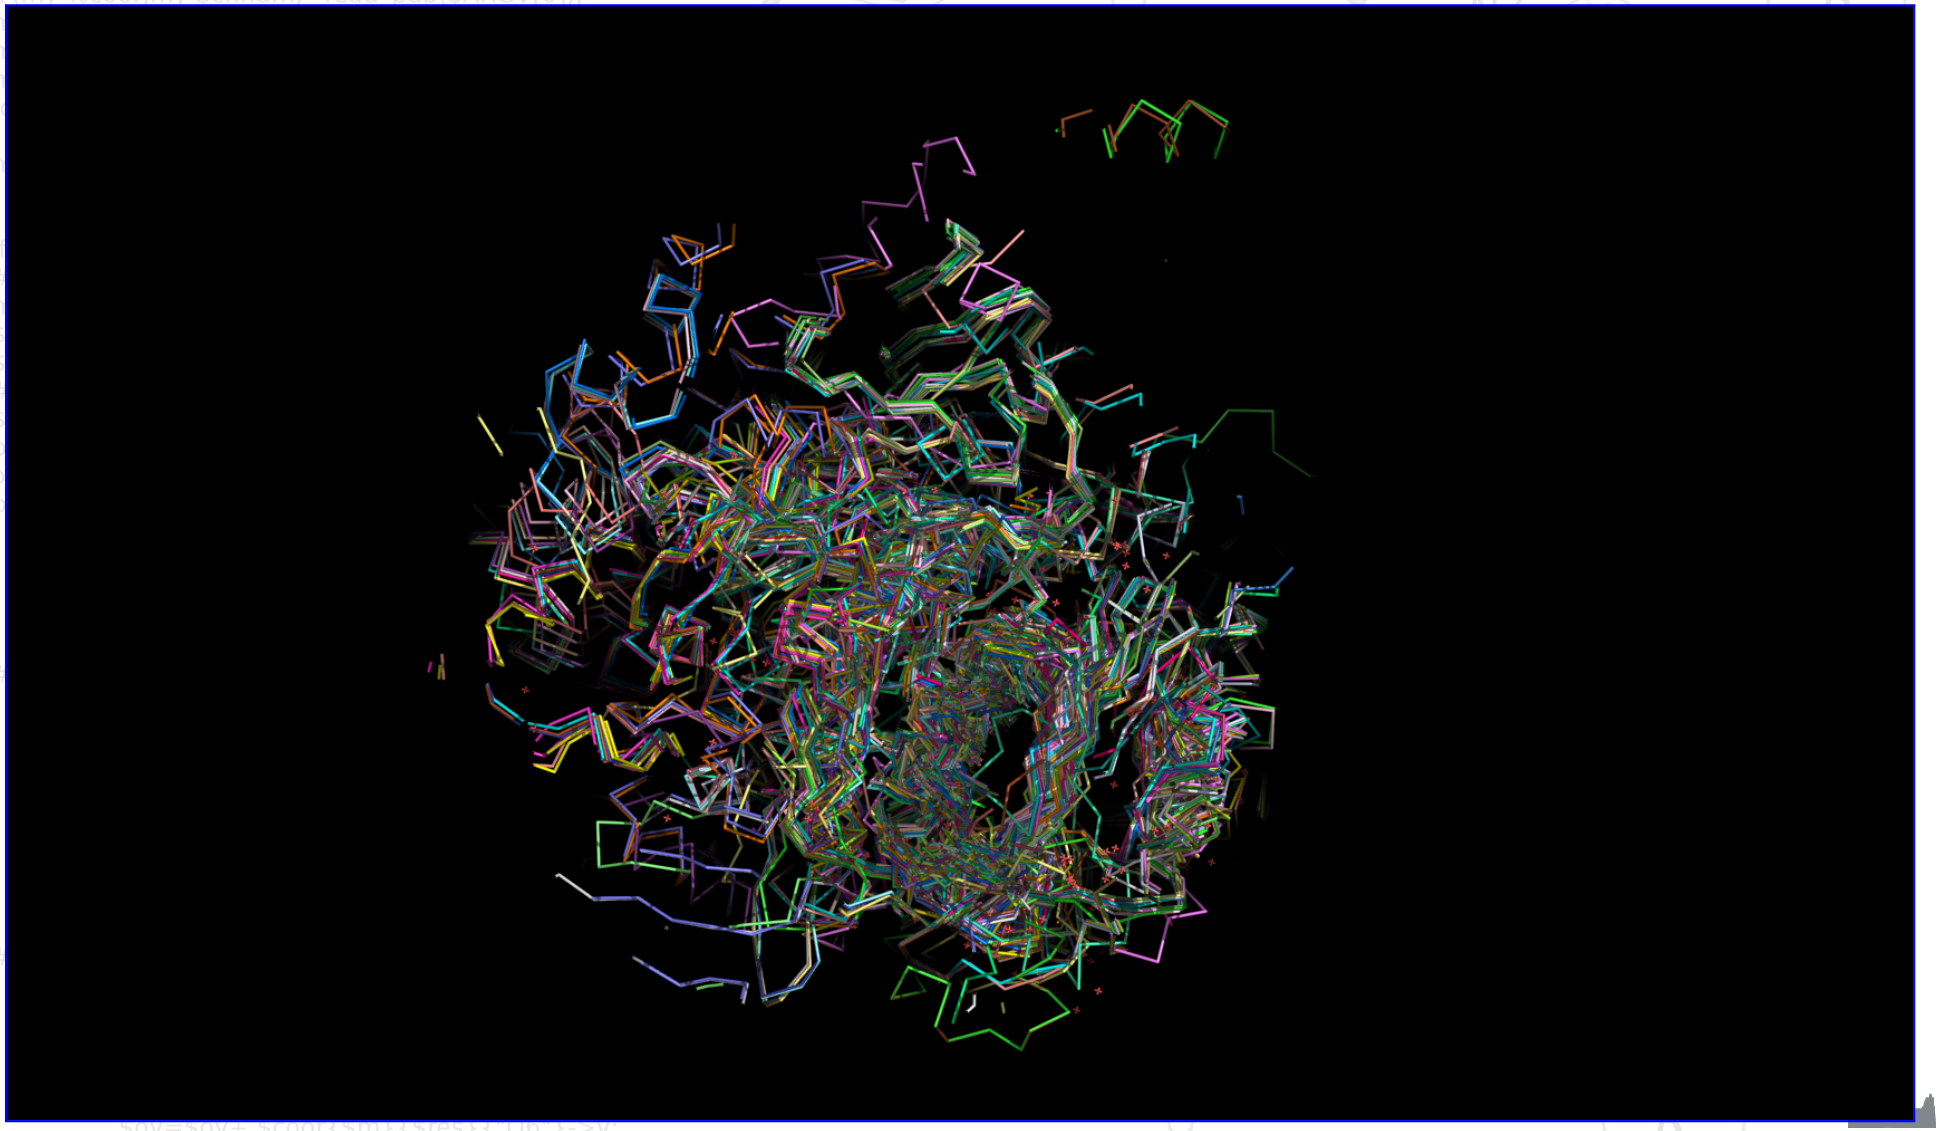

Вопросы?

```
#!/usr/bin/perl
use Math::VectorReal qw( :all );
use strict;

#(my %coor,my $chnum)=read_pdb($ARGV[0]);
my %coor=read_pdb($ARGV[0]);
my $dir=$ARGV[1];
my $ch, my $chnum;
foreach my $r ( sort keys %{$coor{"0"}}){ my $ggg=substr($r,0,1); if ( $ggg ne $ch){$chnum++; $ch=$ggg}   };

my %qwa=find_quart( $coor{"0"} ); my $qnum=keys %qwa;


if ($qnum >0){
#system("mkdir $ARGV[1]");
my $filename=$ARGV[0];
$filename=~ s/^.*\///;
$filename=~ s/\.pdb//;
#$filename=$chnum."_".$qnum."/".$filename.".dat";
$filename="$dir/".$filename.".dat";
print  "$filename\n";
open OUT,">$filename";
print OUT "#INFO  chain $chnum qnum $qnum \n";

  foreach my $m (sort {$a<=>$b} keys %coor){
    my  %qartets= %qwa ; #find_quart( $coor{$m} );
    my  %q= find_q( $coor{$m} );

#       foreach my $q ( keys  %qartets){ print join " ",@{ $qartets{$q} },"\n"}

        foreach my $q ( keys  %qartets){

          my $nx; my $ny; my $nz;
          my $ox; my $oy; my $oz;
             my $r;

          foreach my $res     ( @{ $qartets{$q} }){

#                   print "$q $coor{$m}{$res}{"N9"}->x,"\n";
              $nx=$nx+ $coor{$m}{$res}{"N9"}->x;
              $ny=$ny+ $coor{$m}{$res}{"N9"}->y;
              $nz=$nz+ $coor{$m}{$res}{"N9"}->z;

              $ox=$ox+ $coor{$m}{$res}{"O6"}->x;
              $oy=$oy+ $coor{$m}{$res}{"O6"}->y;
              $oz=$oz+ $coor{$m}{$res}{"O6"}->z;
```