

Факультет биоинженерии и биоинформатики,
Московский государственный университет имени М. В. Ломоносова



Структурные домены. Пространство укладок

Лекция 5, биоинформатика, 4 курс ФББ МГУ, осенний семестр
Злобин А. С., alexander.zlobin@fbb.msu.ru

Классификации структурных доменов

SCOP (<http://scop.mrc-lmb.cam.ac.uk/scop/>)


- ручная детекция доменов
- 4 основных уровня классификации (класс, укладка, суперсемейство, семейство), также группирует по физико-химическому типу
- нестрогая иерархичность
- эволюционный контекст

CATH (<http://www.cathdb.info/>)



- полуавтоматическая детекция доменов
- 4 основных уровня классификации (класс, архитектура, топология, суперсемейство)
- строгая иерархичность
- без контекста

Классификация по физ-хим свойствам

Фибриллярные





Глобулярные




Мембранные

Мембранные белки





Фибриллярные белки




фиброин

Фибриллярные белки



Глобулярные белки



SCOP

В отличие от CATH, ставит своей задачей не просто провести структурную классификацию, а, по-возможности, связать ее с информацией о том, как структуры эволюционируют.

Семейство: есть четкие свидетельства общего происхождения, чаще всего из высокого сходства последовательностей.

Суперсемейство: предположительно общее происхождение, сходство в отдельных структурных деталях, архитектуре активного центра, карманов связывания.

Укладка (фолд): глобальные структурные особенности, топология.

Класс: пропорция элементов вторичной структуры.

Тип: растворимый, мембранный, фибриллярный, неструктурированный.


[About](#)[Contact](#)[Download](#)SUPERFAMILY [Osmotin/thaumatin-like](#)SUPERFAMILY [GH64 beta-glucanase insert domain-like](#)

FAMILY

GH64 beta-glucanase-like

PF16483, comprises two domains from different superfamilies

Function functionally relevant complex structure(s) determined

Show ancestry ☒[Pfam](#)

SCOP ID: 4004596


Representative sequence [Other domains for this sequence](#) [External links](#)

UniProt Q9Z4I2
This domain
3GD0 A:37-401
3GD0 A:37-243,353-401



■ Superfamily domain ■ Family domain

■ Domain only
■ Domain in chain
■ Domain in PDB



Domains [2 entries]

Protein **Laminaripentaose-producing beta-1,3-gluase (LPHase)**Species *Streptomyces matensis*Representative domain [8045656](#)

Represented structures [1]

3GD9 A

ID

Region

Links

[Q9Z4I2](#)

37-401

[UniProt](#)[3GD0](#)

A:37-401

[PDB](#)[RCSB PDB](#)

FOLD [PqqD-like WHD fold](#)

SUPERFAMILY [Winged helix DNA-binding domain](#)

FAMILY

PqqD-like




PF05402

Function known the process in which is implicated

Show ancestry ☒

[Pfam](#)

SCOP ID: 4005476




CATH: уровни классификации

Class - structures are classified according to their secondary structure composition (mostly alpha, mostly beta, mixed alpha/beta or few secondary structures).

Architecture - structures are classified according to their overall shape as determined by the orientations of the secondary structures in 3D space but ignores the connectivity between them.


Topology (fold family) - structures are grouped into fold groups at this level depending on both the overall shape and connectivity of the secondary structures.

Homologous superfamily - this level groups together protein domains which are thought to share a common ancestor and can therefore be described as homologous.




1.10.490.20


Mainly α .Non-bundle.Globin-like.1cpc chain A




Топология




Архитектура





Топология



Архитектура

Данная топология: 1-2-3-4-5


Однако мы вполне можем представить себе случай, когда она будет 1-4-3-2-5

CATH: протокол


1. S-level. Группировка по последовательностям (non-redundancy)
2. Выделение доменов - консенсус по DOMAK, DETECTIVE, PUU. Если консенсус 85% и больше, то присваивается разбиение по DETECTIVE. В противном случае вручную
3. C-level. Подсчет содержания вторичных структур
4. H- и T-level. Структурное выравнивание SSAP. 70% структурного сходства - один T-level. 80% - один H-level. H-levels аннотируются по функции (по возможности)
5. A-level. Вручную

Class


- Преимущественно альфа-спиральные
- Преимущественно бета-листовые
- Смешанные
- Неструктурированные



α




$\alpha\&\beta$




β

Разнообразие фолдов: преимущественно β




β -сверток
 β -roll




β -бочка
 β -barrel

Разнообразие фолдов: преимущественно β





β -сендвич
 β -sandwich




Тройной β -сендвич
3-layer sandwich

Разнообразие фолдов: преимущественно β




β -призма
 β -prism

Разнообразие фолдов: преимущественно β




4-пропеллер
4-propeller



5-пропеллер
5-propeller

Разнообразие фолдов: преимущественно β





6-пропеллер
6-propeller



7-пропеллер
7-propeller

Разнообразие фолдов: преимущественно β



8-пропеллер
8-propeller



α -фолды: α -пучки

alpha-bundles




α -фолды: α -многогранники

Alpha solenoid




α -фолды: α -подковы

Alpha horseshoe




α -фолды: α -бочонки


Alpha-barrels





$\alpha+\beta$ vs α/β




α/β



$\alpha+\beta$



Глобулярные белки с нестандартной укладкой



Superfamily Comparison

Select a CATH node...

A 3-Layer(aba) Sandwich


3.40

CATH ID	3.40
Topologies	126
Superfamilies	577
Domains	86984
Example Domain	2hbaA00 [PDB]



Top of CATH Hierarchy (4 Classes)


▷ C 1	Mainly Alpha	5 Architectures, 405 Folds, 2174 Superfamilies, 90302 Domains
▷ C 2	Mainly Beta	21 Architectures, 244 Folds, 1395 Superfamilies, 110260 Domains
▾ C 3	Alpha Beta	14 Architectures, 634 Folds, 2428 Superfamilies, 229776 Domains
▷ A 3.10	Roll	60 Folds, 248 Superfamilies, 16507 Domains
▷ A 3.15	Super Roll	3 Folds, 7 Superfamilies, 56 Domains
▷ A 3.20	Alpha-Beta Barrel	18 Folds, 63 Superfamilies, 16668 Domains
▷ A 3.30	2-Layer Sandwich	224 Folds, 1178 Superfamilies, 66583 Domains
▾ A 3.40	3-Layer(aba) Sandwich	126 Folds, 577 Superfamilies, 86984 Domains
▷ T 3.40.5	Ribosomal Protein L9; domain 1	10 Superfamilies, 292 Domains
▷ T 3.40.10	DNA Methylphosphotriester Repair Domain	1 Superfamilies, 5 Domains
▷ T 3.40.20	Severin	2 Superfamilies, 290 Domains
▷ T 3.40.30	Glutaredoxin	12 Superfamilies, 4013 Domains
▷ T 3.40.33	Pathogenesis-related Protein p14a	1 Superfamilies, 62 Domains
▷ T 3.40.35	Fructose Permease	1 Superfamilies, 15 Domains
▷ T 3.40.47	Peroxisomal Thiolase; Chain A, domain 1	2 Superfamilies, 1877 Domains
▷ T 3.40.50	Rossmann fold	298 Superfamilies, 52880 Domains
▷ T 3.40.80	Lysozyme-like	1 Superfamilies, 257 Domains
▷ T 3.40.91	Restriction Endonuclease	9 Superfamilies, 265 Domains
▷ T 3.40.109	NADH Oxidase	3 Superfamilies, 288 Domains
▷ T 3.40.120	Alpha-D-Glucose-1,6-Bisphosphate; Chain A, domain 3	1 Superfamilies, 221 Domains
▷ T 3.40.140	Cytidine Deaminase; domain 2	7 Superfamilies, 420 Domains
▷ T 3.40.190	D-Maltodextrin-Binding Protein; domain 2	18 Superfamilies, 5295 Domains
▷ T 3.40.198	Delta-endotoxin CytB	1 Superfamilies, 16 Domains
▷ T 3.40.210	PvuII Endonuclease; Chain A	3 Superfamilies, 35 Domains
▷ T 3.40.220	Leucine Aminopeptidase, subunit E; domain 1	3 Superfamilies, 484 Domains
▷ T 3.40.225	L-fucose-1-phosphate Aldolase	1 Superfamilies, 110 Domains
▷ T 3.40.228	Dimethylsulfoxide Reductase; domain 2	1 Superfamilies, 104 Domains




Growth Of Unique Folds (Topologies) Per Year As Defined By CATH (v4.0.0)

number of folds can be viewed by hovering mouse over the bar


Number



Разные белки - одинаковые укладки




Лактаза бактерии




Шаперон человека

Разные белки - одинаковые укладки



DFP-аза каракатицы




Лектин гриба

Структурное выравнивание/ пространственное совмещение

Структурное выравнивание – сопоставление пар остатков исходя из структурных критериев


Пространственное совмещение – трансформация координат, приводящая к наилучшему наложению сопоставленных атомов (чаще всего C α)



Способы измерить качество наложения: RMSD

$$\text{RMSD}(\mathbf{v}, \mathbf{w}) = \sqrt{\frac{1}{n} \sum_{i=1}^n \|v_i - w_i\|^2} \quad (1)$$

$$= \sqrt{\frac{1}{n} \sum_{i=1}^n ((v_{ix} - w_{ix})^2 + (v_{iy} - w_{iy})^2 + (v_{iz} - w_{iz})^2)} \quad (2)$$




Способы измерить качество наложения: eRMSD

Идея:

- Описать каждую пару оснований внутри структуры как вектор контакта
 - Вектор контакта - вектор между центрами масс оснований
- Оценить сходство структур как разницу векторов

$$eRMSD = \sqrt{\frac{1}{N} \sum_{j,k} |\vec{G}(\tilde{r}_{jk}^{\alpha}) - \vec{G}(\tilde{r}_{jk}^{\beta})|^2}$$



Способы измерить качество наложения: TM-score

Идея:

- Избавиться от влияния длины

$$\text{TM-score} = \max \left[\frac{1}{L_{\text{target}}} \sum_i^{L_{\text{aligned}}} \frac{1}{1 + \left(\frac{d_i}{d_0(L_{\text{target}})} \right)^2} \right]$$

$$d_0(L_{\text{target}}) = 1.24 \sqrt[3]{L_{\text{target}}} - 15 - 1.8$$

Способы измерить качество наложения: GDT_TS


Идея:

- Оценивать наложение по похожим участкам, не учитывать непохожие
- Применяется в оценке качества моделирования структур по последовательностям в соревновании CASP

$$GDT_TS = N(\text{на } i \text{ для которых } d(i^A, i^B) < \text{threshold})$$

где $d(i^A, i^B)$ это расстояние между Calpha атомами

Median Free-Modelling Accuracy



Как получить структурное выравнивание?

- Не получать, взять выравнивание по последовательностям (PyMol align)
- Сделать вручную (бенчмарки для инструментов)
- Сделать алгоритмически

Для написания алгоритма нам нужно определиться со способами


- описать локальную геометрию участка белка
- решить, похожи ли геометрии двух участков
- найти по возможности наилучшее объединение похожих участков

AFP (aligned fragment pairs)

Очень распространенный концепт в алгоритмах структурного выравнивания. AFP это пара подструктур из последовательно идущих остатков белков А и В небольшой фиксированной длины (часто $L=8$).

Идея:

- Рассмотреть все AFP, отфильтровать по схожести их локальных геометрий
- Из оставшихся выбрать “затравку”
- Достраивать “затравку”, стыкуя ее с новыми AFP
Комбинаторно, динамически или Монте-Карло
- Преобразовать цепочку AFP в черновое выравнивание
- Оптимизировать выравнивание
Чтобы добиться наилучшего RMSD



CE (Combinatorial Extension)

Мера сходства геометрий – функции над попарными расстояниями

Способ продления цепочки – переборный с отбраковкой согласно эвристикам

1. Выбор затравки.


Для всех октамеров из белка А, для всех октамеров из белка В попарно определяются АРР. Для i -го АРР:

$$D_i = \frac{1}{m^2} \sum_{k=0}^{m-1} \sum_{l=0}^{m-1} |d_{p_i^A+k, p_i^A+l} - d_{p_i^B+k, p_i^B+l}|$$


Где $m=8$, p_i^A номер остатка белка А, с которого начинается октамер АРР _{i} в А, аналогично p_i^B

Затравки принимаются, если $D_i < 3A$


CE (Combinatorial Extension)



Топологические и нетопологические выравнивания





CE
MATT
FatCat



DALI
SSM

Что не может топологическое выравнивание: круговые перестановки






Круговые перестановки

Не редкость в природе

Можно проектировать:

- Изменить место окончания цепи – расширить набор областей пространства, куда можно продлить цепочку, например, пришивая репортерный белок
- Зимогены активируются путем разрезания – можно сделать конститутивно активированный фермент



CE (Combinatorial Extension)




2. Продление цепочки

Для всех AFP_j , которые не наслаиваются на данный AFP_i (и остальные AFP в цепочке), решается, встроить ли их в цепочку

- 1) $D_j < 3A$
- 2) Вычисляется D_{ij} :

$$D_{ij} = \frac{1}{m} (|d_{p_i^A p_j^A}^A - d_{p_i^B p_j^B}^B| + |d_{p_i^A+m-1, p_j^A+m-1}^A - d_{p_i^B+m-1, p_j^B+m-1}^B| + \\ + \sum_{k=1}^{m-2} |d_{p_i^A+k, p_j^A+m-1-k}^A - d_{p_i^B+k, p_j^B+m-1-k}^B|)$$

$$D_{ij} = \frac{1}{m} (|d_{p_i^A p_j^A}^A - d_{p_i^B p_j^B}^B| + |d_{p_i^A + m - 1, p_j^A + m - 1}^A - d_{p_i^B + m - 1, p_j^B + m - 1}^B| + \\ + \sum_{k=1}^{m-2} |d_{p_i^A + k, p_j^A + m - 1 - k}^A - d_{p_i^B + k, p_j^B + m - 1 - k}^B|)$$



CE (Combinatorial Extension)

Условия для продления цепочки путем добавления AFP_n:

$$D_n < D_0$$

$$\frac{1}{n-1} \sum_{i=0}^{n-1} D_{in} < D_1$$

$$\frac{1}{n^2} \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} D_{ij} < D_1$$

Где $D_0 = 3A$, $D_1 = 4A$

CE (Combinatorial Extension)

3. Выбор лучшей финальной цепочки

Идея: использовать такую меру сходства структур, которая отражала бы некий баланс между требованием к максимизации длины выравнивания и минимизации RMSD.

Решение: вероятность случайно получить выравнивание такой же длины с таким же или меньшим числом гэпов и с таким же или меньшим RMSD.

Авторы взяли много пар структур (какие-то из них похожи, какие-то нет) и построили выравнивания при помощи своего алгоритма. Для каждого выравнивания можно посчитать длину и RMSD. Для каждой длины выравнивания можно получить распределение RMSD и числа гэпов по такой случайной выборке.

CE (Combinatorial Extension)

4. Оптимизация

Если есть черновое выравнивание, то его можно оптимизировать. А именно, можно:

- Удлинять выровненные участки.
- Укорачивать их.
- Сдвигать гэпы.

Каждое такое изменение соответствует некоторому новому выравниванию. И, следовательно, некоторому совмещению. И у него есть длина, RMSD и Z-score. Можно посмотреть, увеличился ли он от каждого возможного изменения.

Алгоритм CE рассматривает последовательности таких изменений, выбираемые случайным образом. Те последовательности, которые ведут к сильному ухудшению Z-score отбраковываются.

Похожие идеи

Комбинаторный перебор продлений может быть заменен на **динамическое программирование**. В таком случае процедура становится похожей на алгоритм Нидлмана-Вунша, только S_{ij} вместо значения из матрицы аминокислотных замен становится величиной соответствия AFP_{ij} .

Старт алгоритма динамического программирования с самого раннего по ходу последовательностей белков A и B подходящего AFP.


$S(k)$ – лучший скор для цепочки, оканчивающейся на AFP_k

$$S(k) = D_k + \max_m (\max (S(m) + a(m \rightarrow k)), 0)$$


Качество самого AFP_k

“Цена” включения
 AFP_k в цепочку


DAI – матрицы расстояний 6x6



3D



2D



1D

one pair

an overlapping pair

the two pairs combined

collapse

DALI

Целевая функция

$$S = \sum_{i=1}^L \sum_{j=1}^L \phi(i, j) \quad , \text{ где } i \text{ и } j - \text{ координаты в матрице (= в выравнивании)}$$

$$\phi^R(i, j) = \theta^R - |d_{ij}^A - d_{ij}^B|$$

$$\phi^E(i, j) = \left\{ \begin{array}{l} (\theta^E - \frac{|d_{ij}^A - d_{ij}^B|}{d_{ij}^*}) \omega(d_{ij}^*), \quad i \neq j \\ \theta^E, \quad i = j \end{array} \right\}, \omega(r) = e^{-\frac{r^2}{400}}$$



Смысл: сильно непохожие расстояния вообще не надо учитывать.

DALI решает задачу поиска лучшей цепочки выровненных пар гексамеров с помощью алгоритма Монте-Карло


Вторичная структура как AFP

142


C.A. ORENGO ET AL.



Гибкое выравнивание



SE не примет продление
цепи через добавление
зеленого AFP




FatCat и MATT допускают изгибы при
оценке возможности добавления AFP
NB: финальный RMSD все равно
рассчитывается по интактным структурам

Алгоритм PDBeFold (SSM)


Сравниваем между собой взаиморасположения пар элементов вторичной структуры

- Отдаленно напоминает DALI – там мы сравнивали взаиморасположения пар гексамеров
- Однако в DALI мы описывали его как матрицу расстояний
- А в SSM мы присвоим каждому элементу вторичной структуры вектор из начала в конец и зададим их взаиморасположение набором чисел




Будем использовать эти наборы, чтобы решать, сопоставляется ли пара элементов из белка А с парой элементов из белка В, т.е. похожее ли между элементами взаиморасположение в двух структурах

Алгоритм PDBeFold (SSM)



Это модифицированный пример из оригинальной статьи. Я добавил к первой структуре тяж S_4 . Вопрос: какие элементы вторичной структуры тут расположены примерно одинаково и в А, и в В?

Алгоритм PDBeFold (SSM)




Это модифицированный пример из оригинальной статьи. Я добавил к первой структуре тяж S_4 . Вопрос: какие элементы вторичной структуры тут расположены примерно одинаково и в А, и в В?

Ответ: H, S_1, S_2, S_3 .

1. Рассмотрим все пары элементов из первой структуры:
 $(H, S_1), (H, S_2), (H, S_3), (H, S_4), (S_1, S_2), (S_1, S_3), (S_1, S_4),$
 $(S_2, S_3), (S_2, S_4), (S_3, S_4)$
 + еще 10 $(S_1, H), (S_2, H)$ и т.д.
2. Рассмотрим все пары элементов из второй структуры:
 $(H', S_1'), (H', S_2'), (H', S_3'), (S_1', S_2'), (S_1', S_3'),$
 (S_2', S_3')
 + еще 6 $(S_1', H'), (S_2', H')$ и т.д.
3. Рассмотрим двойки пар из п. 1 и 2 (например, $(H, S_1) + (H', S_3')$ и проч.)
 Вопрос: сколько всего таких двоек?
 Ответ: $20 \times 12 = 240$.
 Вопрос: Все ли такие двойки пар соответствуют парам элементов, которые одновременно могут быть выровнены?

Алгоритм PDBeFold (SSM)



Рассмотрим двойки пар (например, (H, S_1) + (H', S_3') и проч.) – это гипотезы об одновременном выравнивании пар элементов

Вопрос: Все ли такие двойки пар соответствуют парам элементов, которые одновременно могут быть выровнены?

$(H, S_1) + (H', S_3')$

Может, т.к. спираль соответствует спирали, а тяж - тяжу

$(H, S_1) + (S_1', S_3')$


Не может, т.к. спираль не может быть выровнена с β -тяжем

$(S_1, S_2) + (S_1', S_3')$

Может

Из рисунка видно, что не все эти двойки реально выровнены. Но алгоритм этого пока не знает – это надлежит установить.

Алгоритм PDBeFold (SSM)



$$(H, S_1) + (H', S'_1')$$

$$(H, S_2) + (H', S'_2')$$

$$(H, S_3) + (H', S'_3')$$

$$(S_1, S_2) + (S'_1, S'_2')$$

$$(S_1, S_3) + (S'_1, S'_3')$$


$$(S_2, S_4) + (S'_1, S'_3')$$

Отберем из всех двоек вида те, которые потенциально могут быть выровнены. Это будут вершины графа. (На рисунке ниже показаны далеко не все вершины.)

Часть вершин соответствует правильному выравниванию. Часть – нет, но мы этого пока не знаем. Такова, например, двойка $(S_2, S_4) + (S'_1, S'_3')$. Как видно из рисунка в правильном выравнивании такой двойки нет. Но вообще говоря, это две пары тяжей, идущих в одном направлении, примерно с одинаковым расстоянием между ними.

Теперь соединим ребрами те вершины, между которыми нет противоречия.

Алгоритм PDBeFold (SSM)




Теперь соединим ребрами те вершины, между которыми нет противоречия.

Например, двойки
 $(H, S_1) + (H', S'_1)$ и
 $(H, S_3) + (H', S'_3)$
 вполне могут быть в одном выравнивании.

А двойки
 $(S_1, S_3) + (S'_1, S'_3)$ и
 $(S_2, S_4) + (S'_1, S'_3)$
 - нет. Действительно, S'_1 не может быть
 одновременно выровнен
 и с S_1 , и с S_2 .


Клика в таком графе соответствует
 максимальному множеству выровненных
 элементов.




Алгоритм PDBeFold (SSM)

Далее, заменим каждый SSE на точку (его центр). Поскольку у нас уже есть списки совпадающих элементов, эти точки можно совместить. Получится черновое совмещение структур.

Теперь надо перейти от выравнивания элементов вторичной структуры к выравниванию последовательностей.



Для совпадающих SSE (см. предыдущий этап) выбирает 3-4 аминокислоты, наиболее близких друг к другу. Затем выравнивание расширяется на весь тяж или спираль.




Для всех остальных алгоритм находит взаимно наиболее близкие C_α атомы. Соседние с ними пары атомов также считаются выровненными.

Алгоритм PDBeFold (SSM)


Далее, заменим каждый SSE на точку (его центр). Поскольку у нас уже есть списки совпадающих элементов, эти точки можно совместить. Получится черновое совмещение структур.

Теперь можно перейти от выравнивания элементов вторичной структуры к выравниванию последовательностей. При этом близко расположенные C_α атомы считаются выровненными и это выравнивание распространяется на их соседей по полипептидной цепочке.


Теперь у нас есть **черновое выравнивание** последовательностей. Ему соответствует некое совмещение структур, длина выравнивания, RMSD и Q-score. Его можно **оптимизировать**: менять разными способами, строить новое совмещение и добиваться увеличения Q. И так много-много раз, пока **решение не стабилизируется**.




1TIE



4FGF




1TIE





4FGF



Align




Super



Super



CE (cealign)



TM-align

(нет в PyMol)

