

Predikce struktury proteinu ze sekvence

Sekvence <-> Přírodní zákony

Sekvence <-> Databáze sekvencí

Sekvence <-> Databáze struktur

Frekvence

$$F(x) = P(x) \cdot N$$

Je vyšší u řetězců, které jsou součástí často používaných struktur

Vzájemná informace

$$MI(x,y) = P(x,y) \log (P(x,y) / (P(x)*P(y)))$$


Je vyšší uvnitř struktur než na jejich rozhraní, vyjádřuje korelaci

Entropie


$$H(x) = - p(x) * \log(p(x))$$

Určuje míru neuspořádanosti, nebo taky potřebu informace pro definování určitého stavu


Spoluvýskyt krátkých sekvencí v proteinech



Jedním z důvodů spoluvýskytu krátkých sekvencí je, že spolu vytvářejí samostatný doménu, která se vyskytuje ve větším počtu proteínů




Vyhodnocení hledání domén



Počet korelací
procházejících
daným místem
proteinu Atg07210
porovnaný se záznamem
v databáze PRODOM

Celková struktura sekvence jak se jeví při srovnání s ostatními sekvencemi v proteinových databázích




Kubota, Lee, 1999. Mostly-unsupervised statistical segmentation of Japanese: application to kanji.

kanji, hiragana, katakana – znaky různé úrovně

kanji jsou na úrovni našich slabik a tvoří polovinu slov


sekvence kanji se často dají segmentovat různými způsoby



漢英字典刊行会

Kubota, Lee, 1999. Mostly-unsupervised statistical segmentation of Japanese: application to kanji.

Pro každou mezeru se vypočítá hodnota $(s_1+s_2)/(t_1+\dots+t_n)$



漢英字典刊行会

Vstupní data pro analýzu textu ve formátě FASTA

>SENTENCE

THECALLOTHEWILD

>SENTENCE

BYJACKLONDON

>SENTENCE

CHAPTERONE

>SENTENCE

BUCKDIDNOTREADTHENEWSPAPERSORHEWOULDHAVEKNOWNTHATTRUBLEWASBREWING

Segmentace textu v angličtině

~50%

	<i>2-gram</i>
<	7.046
THE	3.965
CALL	1.771
OF	5.683
THE	3.37
WILD	0.843
<	0.628
BY	15.17
JACK	10.951
LOND	3.267
ON	4.759
<	8.495
CHAP	5.136
TER	2.424
ONE	1.69
<	4.565
INTO	3.996
THE	6.199
PRIM	2.914
ITI	4.348
VE	1.674

~20%

	<i>4-gram</i>
<	1.024
THEC	2.834
ALL	10.841
OFTHEW	4.86
ILD	19.2
<	2.062
BY	4.632
JACK	2.758
LONDON	14.962
<	2.025
CHAPTERONE	0.922
<	10.137
IN	1.555
TOTHEP	4.058
RIMI	3.24
TIVE	6.681


~20%


	<i>2-gram</i>
<	1.396
BU	1.717
CK	57.205
DID	3.357
NOT	3.116
READ	3.744
THE	1.733
NEW	8.714
SPAP	3.266
ER	2.745
SOR	18.096
HE	3.303
WOU	2.25
LD	2.73
HA	4.572
VE	5.867
KNOW	6.71
NTH	2.046
ATT	1.74
ROU	11.28
BLEWASB	5.806
REW	3.149
ING	22.372

~35%

	<i>4-gram</i>
<	8.735
BUCK	29.116
DI	1.647
DNOT	7.055
REA	6.81
DTHEN	3.782
EWS	2.008
PAPERSOR	7.206
HEW	1.587
OULD	6.122
HAVE	25.589
KNOWN	7.595
THAT	8.573
TROUBL	12.29
EWAS	8.537
BREWING	3.078

Weisser D, Klein-Seetharaman J (2004). Identification of fundamental building blocks in protein sequences using statistical association measures. ACM SAC 2004






Predikce struktury proteinu ze sekvence

<http://hpcio.cit.nih.gov/Folding.htm>

- 1) Modelování struktury na základě homologie
(BLAST PDB)
- 2) Threading
(ENERGY FUNCTION/PDB)
<http://compbio.ornl.gov/structure/prospect>
- 3) Skládání ze sekvenčně-strukturních fragmentů
(I-SITES=CLUSTERING/PDB)
- 4) Ab initio modelování
(ENERGY FUNCTIONS)

Threading




Highest-scoring fold above threshold
is probable structure



Figure 4-25 The method of profile-based threading. A sequence of unknown structure is forced to adopt all known protein domain folds, and scored for its suitability for each fold. The z -value relates the score for the query sequence to the average score for a set of random sequences with the same amino-acid composition and sequence length. A very high z -score indicates that the sequence almost certainly adopts that fold. Sequences can be submitted online for threading by PSIPRED (<http://bioinf.cs.ucl.ac.uk/psipred/index.html>).

I-Sites

Princip



SEKVENCE

STRUKTURY

I-Sites

PSSM
Paradigma

Figure 3. Diverging Type-I site. (left_247-255)






Figure 4. Type-I β -hairpin. (2b6kh 179-191)




Příklady predikce struktury (Rosetta)

<http://www.bioinfo.rpi.edu/~bystrc/hmmstr/server.php>



Příklady predikce struktury (Robetta)

<http://robbetta.bakerlab.org/>




Rosetta Tackles the

Extreme Origami

of Protein Folding

David Baker's model is producing remarkably accurate predictions.

<http://www.hhmi.org>



<http://robbetta.bakerlab.org/documents/faqs.jsp>



ROBBETTA
Full-chain Protein Structure Prediction Server

Structure Prediction Fragment Libraries Alanine Scanning
[Queue] [Submit] [Queue] [Submit] [Queue] [Submit]
[Register / Update] [Docs / FAQs] [Login]

Frequently Asked Questions

- [What is Robetta?](#)
- [What are Fragment Libraries?](#)
- [What is Interface Alanine Scanning?](#)
- [What is Ginzu?](#)

Často používané modely sekvence

PSSM – Positional specific scoring matrix


(PWM – Positional weight matrix)

	1	2	3	4	5	...
A	12	0	3	2	1	
C	0	1	45	11	2	
D	1	3	2	0	1	
...						

HMM – Hidden Markov Model



Kontaktní mapy



**Analýzou kontaktních map je možné
najít přírodou často používané typy kontaktů**

