

IV108 - Bioinformatika II

Ing. Matej Lexa, PhD.
<http://www.fi.muni.cz/~lexa/>

Čt	15:00	B411	Přednáška
	16:00	B117	Cvičení
Čt	13:00 – 15:00	C506	Konzultace

Navazuje na IV107 (Bioinformatika)

Probíhá paralelně s IV105-6 (Seminář Út 17:00 B411)

IV110,IV114 (Projekt Ut 8:00 B410)

Bloky přednášek:

- 1) Informační obsah a struktura biologických sekvencí**
- 2) Nové metody sekvenace, algoritmy na sekvencích**
- 3) Vyhledávací nástroje**
- 4) Předpovídání a manipulace se strukturami biomolekul**

Zkouška: Písemná 50 bodů. Nejlépe hodnocené práce ve cvičení můžou přispívat k celkovému bodovému hodnocení u zkoušky do výšky 10 bodů. Studijní materiály budou specifikovány průběžně.


Klasifikace

Zkouška


Vyřešen problém z cvičení = 1b (max 10b = 20%)

Písemná zkouška max. 40b (80%)

- * **A - 91-100 %**
- * **B - 81 - 90 %**
- * **C - 71 - 80 %**
- * **D - 61 - 70 %**
- * **E - 51 - 60 %**
- * **F - 0 - 50 %**




Studijní literatura




Neil C Jones and Pavel A Pevzner (2004).
An introduction to Bioinformatics
Algorithms.
The MIT Press, 454 s.
ISBN 0-2621-0106-8

Doplňková literatura



M.S.Waterman (1995).
Introduction to Computational Biology.
Chapman & Hall/CRC, 448 s.
ISBN 0-4129-9391-0




M.J.Zvelebil. And J.O.Baum (2007).
Understanding Bioinformatics.
Taylor & Francis, 750 s.
ISBN: 0-8153-4024-9

Co dělá bioinformatik

- Umí pracovat s velkými datovými soubory
- Moudrými triky ovláda výkonné počítače
- V datech hledá zajímavé subsekvence
- Srovnává podobné sekvence
- Předpovídá strukturu a funkci genů a proteinů
- Studuje vývoj sekvencí a organismů
- Data a výsledky analýz zobrazuje graficky

DNA – RNA – PROTEIN



SEKVENCE – STRUKTURA – FUNKCE

GENOTYP

```
>chsl  
atgacagaat  
acaggatgac  
tatgacgtga  
cggcttata  
gatgacc...
```

GEN.KÓD

```
>chsl  
MFVDDHLA  
VNQNFYLR  
SHRQL...
```

STRUKTURA



FENOTYP



FUNKCE

Biologická sekvence (BS)

ACAGTGCAGGCATGACGATGACGCAGCAGATTGACAGAGACCGATAGCAGCAT


MASAQSFYLLHLAVDDFMNGAGVLSHERELLFYDENKIHDIVISMNDENMNQ

Jazyk



THIS IS JUST A SIMPLE SENTENCE IN ENGLISH FOR YOUR INSPIRATION

Informace

<http://en.wikipedia.org/wiki/Information>




Biologická sekvence jako informace, život jako komunikace mezi buňkami, DNA jako komunikační kanál



Sekvence jako Markovův řetězec

NCMKLFQCDSHL


$$P(X_{i+1} | X_i) = P(X_{i+1} | X_0, \dots, X_i)$$



Sekvence jako Markovův řetězec

NCMKLFQCDSHL

NCM, CMK, MKL, KLF, LFQ, FQC, QCD, CDS, DSH, SHL



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

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

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




Co vyjadřuje frekvence v biologických sekvencích

```
[lexa@peleus prot]$ egrep -c "SSS" ATH1.fa
```

```
15927
```

```
[lexa@peleus prot]$ egrep -c "WWW" ATH1.fa
```


```
75
```



Co vyjádřuje entropie v biologických sekvencích

TATATAA
TATAAAA
TATATAT
TATAAAAT

TATA.A. konsensus
TATAWAW RE, W=[TA]
0000101 entropie



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

Jiný pohled na entropii (podmíněná entropie)

```
[lexa@peleus prot]$ egrep -c MASAL. ATH1.fa
```

```
19
```

```
[lexa@peleus prot]$ egrep -c MASALL ATH1.fa
```

```
0
```

```
[lexa@peleus prot]$ egrep -c MASALE ATH1.fa
```

```
7
```

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

Co vyjádřuje MI v biologických sekvencích


```
$ egrep -c "." ATH1.fa  
233194  
$ egrep -c "C..C" ATH1.fa  
8196  
$ egrep -c "H..H" ATH1.fa  
7398  
$ egrep -c C..C.+H..H\|H..H.+C..C ATH1.fa  
1005  
$ bc  
bc 1.06  
8196*1000/233194  
35  
7398*1000/233194  
31  
0.035*0.031*233194  
233.194
```

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

Co vyjádřuje MI v biologických sekvencích

```
$ egrep -c "." ATH1.fa  
233194  
$ egrep -c "C..C" ATH1.fa  
8196  
$ egrep -c "H..H" ATH1.fa  
7398  
$ egrep -c C..C.+H..H\|H..H.+C..C ATH1.fa  
1005  
$ bc  
bc 1.06  
8196*1000/233194  
35  
7398*1000/233194  
31  
0.035*0.031*233194  
233.194
```

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



Shannon 1948. A mathematical theory of communication.

1. Zero-order approximation (symbols independent and equiprobable).

XFOML RXKHRJFFJUJ ZLPWCFWKCYJ FFJEYVKCQSGHYD QPAAMKBZAACIBZL-HJQD.

2. First-order approximation (symbols independent but with frequencies of English text).

OCRO HLI RGWR NMIELWIS EU LL NBNESEBYA TH EEI ALHENHTTPA OOBTTVA NAH BRL.

3. Second-order approximation (digram structure as in English).

ON IE ANTSOUTINYS ARE T INCTORE ST BE S DEAMY ACHIN D ILONASIVE TU-COOWE AT TEASONARE FUSO TIZIN ANDY TOBE SEACE CTISBE.

4. Third-order approximation (trigram structure as in English).

IN NO IST LAT WHEY CRATICT FROURE BIRS GROCID PONDENOME OF DEMONSTURES OF THE REPTAGIN IS REGOACTIONA OF CRE.

5. First-order word approximation. Rather than continue with tetragram, ..., n -gram structure it is easier and better to jump at this point to word units. Here words are chosen independently but with their appropriate frequencies.


REPRESENTING AND SPEEDILY IS AN GOOD APT OR COME CAN DIFFERENT NATURAL HERE HE THE A IN CAME THE TO OF TO EXPERT GRAY COME TO FURNISHES THE LINE MESSAGE HAD BE THESE.

6. Second-order word approximation. The word transition probabilities are correct but no further structure is included.

THE HEAD AND IN FRONTAL ATTACK ON AN ENGLISH WRITER THAT THE CHARACTER OF THIS POINT IS THEREFORE ANOTHER METHOD FOR THE LETTERS THAT THE TIME OF WHO EVER TOLD THE PROBLEM FOR AN UNEXPECTED.

The resemblance to ordinary English text increases quite noticeably at each of the above steps. Note that

Běžná sekvence proteinu má informační obsah několika SMS zpráv.



Běžná sekvence proteinu má informační obsah několika SMS zpráv.

