


Praktične vaje pri predmetu Biokemijska informatika

7. vaja

Prileganje zaporedij



	G	C	A	T	G	C	U
G	-1	1	0	-1	-2	-3	-4
A	-2	0	0	1	0	-1	-2
T	-3	-1	-1	0	2	-1	0
T	-4	-2	-2	-1	1	1	-1
A	-5	-3	-3	-1	0	0	-1
C	-6	-4	-2	-2	-1	-1	0
A	-7	-5	-3	-1	-2	-2	0

AAB24882
AAB24881

TYHMCQFHCRVNNHSGEKLYECNERSKAFCSCPSSLQCHKRQRQIGEKTHEHNQCGKAFFP 60
-----YECNQCGKAFAQHSSLKCHYRTHIGEKPYECNQCGKAFSK 40

AAB24882
AAB24881

PSHLQYHERIHTGEKPYECHQCGQAFKKCSLLQRHKRTHTGEKPYE-CNQCGKAFAQ- 116
HSHLOCHKRHTGEKPYECNOCGKAFSOHGLLQRHKRTHTGEKPYMNVINMYKPLHNS 98

Miha Pavšič
april 2014

7. vaja: Prileganje zaporedij

Metode za prileganje zaporedij

Metode

Prileganje dveh zaporedij (pairwise sequence alignment):

- točkovni diagram
 - dinamično programiranje
 - metode besed oz. nizov

Prileganje večih zaporedij (*multiple sequence alignment*):

- dinamično programiranje
 - progresivne metode
 - iteracijske metode
 - iskanje motivov
 - druge metode (HMM, genetski algoritmi, ...)

Pregled vaje


Prileganje dveh zaporedij:

- točkovni diagram (*dot plot*) → Excel in spletna orodja
 - lokalno in globalno prileganje:
 - algoritmi (dinamično programiranje):
 - Needleman-Wunsch (globalno) → Excel
 - praktični primeri uporabe → spletna orodja

Navodila za vse naloge so v obliki kviza v spletni učilnici.

Točkovni diagram (*dot plot*, *dot-matrix plot*)

- najstarejša metoda primerjave dveh zaporedij:
 - koncept je enostaven
 - kvalitativne narave
 - analiza večjih vzorcev / v večjem merilu je zamudna
 - dobimo celo družino prileganj posameznih regij zaporedij, ki ju primerjamo
 - vizualna identifikacija insercij, delecij, ponovitev in obratnih ponovitev
 - ponovitve na enostaven način identificiramo tudi, če zaporedje primerjamo s samim seboj



- najbolj enostaven primer: točka za identičnost, prazno polje za razliko (primer zgoraj)
 - kompleksnejši primer: velikost/barva točke je povezana s stopnjo podobnosti (npr. E in D sta si bolj podobna kot E in K) – upoštevamo matriko zamenjav (*substitution matrix*)
 - precej šuma → zmanjšamo ga z uporabo okna (primerjamo dva niza določene velikosti)

Algoritem Needleman-Wunsch

za globalno prileganje dveh zaporedij

Osnovni koraki:

1. priprava inicializacijske matrike
2. priprava seštevalne matrike
3. sledenje v seštevalni matriki in izpis prileganja

The diagram shows three stages of the algorithm:

- inicializacija (Initialization):** A 9x8 grid where each row and column is labeled with the bases A, C, T, G. The first row contains values 0, 1, 0, 0, 0, 0, 1, 0. Subsequent rows are all 0s.
- seštevanje (Addition):** The same grid as initialization, but with colored cells indicating scores: a green cell at (A, C) with value 4, a red cell at (T, T) with value 2, and a yellow cell at (C, A) with value 1.
- sledenje (Tracing):** The final 9x8 grid showing the path of highest scores. Cells are colored based on the path: yellow for main diagonal, red for off-diagonal, and green for the start cell (A, C).

V nadaljevanju si bomo pogledali osnoven algoritem, ki ne upošteva neke posebne matrike zamenjav.

Algoritem Needleman-Wunsch

KORAK 1: Priprava inicializacijske matrike

Pripravimo matriko, ki je podobna točkovnemu diagramu.
Za enakost v našem primeru napišemo 1, za neenakost pa 0.

Zaporedje 1: **ACTTATCA**

Zaporedje 2: **CTTGATCA**

The diagram shows two stages of creating an initial substitution matrix:

- Initial State:** An 8x8 grid where each row and column is labeled with the bases A, C, T, G. The first row contains values 0, 1, 0, 0, 0, 0, 1, 0. Subsequent rows are all 0s.
- Final State:** The same grid, but with values filled in based on the comparison of the two sequences. For example, at position (A, C), both bases are the same, so the value is 1. At (T, T), they are the same, so 1. At (C, A), they are different, so 0. Other positions are also filled according to the sequences.

Pri izdelavi inicializacijske matrike bi v kompleksnejšem primeru uporabili matriko zamenjav (*substitution matrix*), prav tako pa bi upoštevali različne vrednosti za vrzeli (za slednje v naslednjem koraku – seštevanje).

Algoritem Needleman-Wunsch

KORAK 2: Seštevalna matrika

Na **posameznih mestih** seštevalne matrike:

- vrednost na **ekvivalentem mestu v inicializacijski matriki** in
- največjo vrednost v **stolpcu nižje in desno ter vrstici nižje in desno v seštevalni matriki**.

	A	C	T	T	A	T	C	A
C	0	1	0	0	0	0	1	0
T	0	0	1	1	0	1	0	0
T	0	0	1	1	0	1	0	0
G	0	0	0	0	0	0	0	0
A	1	0	0	0	1	0	0	1
T	0	0	1	1	0	1	0	0
C	0	1	0	0	0	0	1	0
A	1	0	0	0	1	0	0	1

inicializacijska matrika

	A	C	T	T	A	T	C	A
C								
T								
T								
G								
A								
T								
C								
A								

seštevalna matrika

vrednost v celici seštevalne matrike: $M_{ij} = M_{ij}^* + \max(M_{k, j+1}, M_{i+1, l})$

M_{ij}^* je celica v inicializacijski matriki $k > i, l > j$

V prikazanem primeru je vrednost za vrzel enaka 0. V primeu ne-ničelne vrednosti (je pa <0) bi slednjo prišteli pri pomiku navzdol ali navzgor.

Algoritem Needleman-Wunsch

KORAK 3: Sledenje v seštevalni matriki

	A	C	T	T	A	T	C	A
C	6	7	5	4	3	2	2	0
T	5	5	6	5	3	3	1	0
T	4	4	5	5	3	3	1	0
G	4	4	4	4	3	2	1	0
A	4	3	3	3	4	2	1	1
T	2	2	3	3	2	3	1	0
C	1	2	1	1	1	1	2	0
A	1	0	0	0	1	0	0	1




ACTT-ATCA
-CTTGATCA

tu začnemo

- premiki po **diagonali** pomenijo **enakost**
- premiki **gor ali dol** pomenijo **vrzel**

Lokalno prileganje

Lokalno prileganje pride v poštev npr. pri primerjavi zaporedij proteinov, ki vsebujejo homologne domene, ki pa niso nujno enako razvrščene, se ne ponovijo v enakem številu, lahko pa so prisotne tudi druge (sicer različne) domene.



Matrike zamenjav (substitucijske matrike, substitution matrices)

- Z njimi opišemo frekvenco zamenjav nukleotidov ali aminokislinskih ostankov.
- Za proteine se pogosto uporablja matrika **BLOSUM62**.

NATURE BIOTECHNOLOGY VOLUME 26 NUMBER 3 MARCH 2008

BLOSUM62 miscalculations improve search performance

C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	
C	9																		C	
S	-1	4																	S	
T	-1	1	5																T	
P	-3	-1	-1	7															P	
A	0	1	0	-1	4													A		
G	-3	0	-2	-2	0	6												G		
N	-3	1	0	-2	-2	0	6											N		
D	-3	0	-1	-1	-2	-1	1	6										D		
E	-4	0	-1	-1	-1	-2	0	2	5									E		
Q	-3	0	-1	-1	-1	-2	0	0	2	5								Q		
H	-3	-1	-2	-2	-2	-2	1	-1	0	0	8							H		
R	-3	-1	-1	-2	-1	-2	0	-2	0	1	0	5						R		
K	-3	0	-1	-1	-1	-2	0	-1	1	1	-1	2	5					K		
M	-1	-1	-1	-2	-1	-3	-2	-3	0	-2	-1	-1	5					M		
I	-1	-2	-1	-3	-1	-4	-3	-3	-3	-3	-3	1	4					I		
L	-1	-2	-1	-3	-1	-4	-3	-4	-3	-2	-3	-2	2	2	4			L		
V	-1	-2	0	-2	0	-3	-3	-3	-2	-3	-3	-2	1	3	1	4		V		
F	-2	-2	-2	-4	-2	-3	-3	-3	-1	-3	-3	0	0	0	-1	6		F		
Y	-2	-2	-2	-3	-2	-3	-2	-3	-2	-1	2	-2	-2	-1	-1	-1	7	<th>Y</th>	Y	
W	-2	-3	-2	-4	-3	-2	-4	-4	-3	-2	-2	-3	-3	-1	-3	-2	1	2	11	W

BLOSUMXX

XX = za pripravo matrice so bila vsa zaporedja, ki so >80% identična, združena v eno, s čimer se zmanjša prispevek zelo podobnih zaporedij; manjši **XX** → primerno za primerjavo manj podobnih zaporedij