

Academie toegepaste biowetenschappen en chemie

Bio-Informatica

Course 3



5. Proteins and alignments

Onderzoeksvragen genomonderzoek

HIV kan bij de mens AIDS veroorzaken.

AIDS=Acquired Immune Deficiency Syndrome

Vooral HIV-1 erg gevaarlijk (pandemie)

I. Waarom is HIV-1 hoog virulent?

II. Wat is de fylogenetische oorsprong van HIV-1?

Overzicht onderzoeksplan 3b

Week	Onderwerp	Activiteiten	
1	Oriëntatie op onderwerp Sequenties verzamelen	Inlezen Stap 1	NCBI database
2	GC percentage	Stap 2	Python script
3	Codon gebruik	Stap 3	Python script
4	Eiwit karakterisering / aminozuren	Stap 4	Python script
5	Kenmerken oppervlakte proteïnen	Stap 5	Python script
6	Fylogenetisch onderzoek	Stap 6	Bioinf tools
7	Onderzoeksverslag		

Vandaag

Herhaling vorige week

Uitleg deze week

Deze week

Alignments

Wat is een alignment?

Waarom doen we alignments?

De kwaliteit van alignments.

Alignments en evolutie?

Hfst 3 Pevsner blz 69-78

Sequentie alignments

Wat is het?

Sequentie alignments

Wat is het?

Vergelijken van twee of meer DNA, RNA of eiwit sequenties.

Sequentie alignments

Wat is het?

Vergelijken van twee of meer DNA, RNA of eiwit sequenties.

Waarom?

Sequentie alignments

Wat is het?

Vergelijken van twee of meer DNA, RNA of eiwit sequenties.

Waarom?

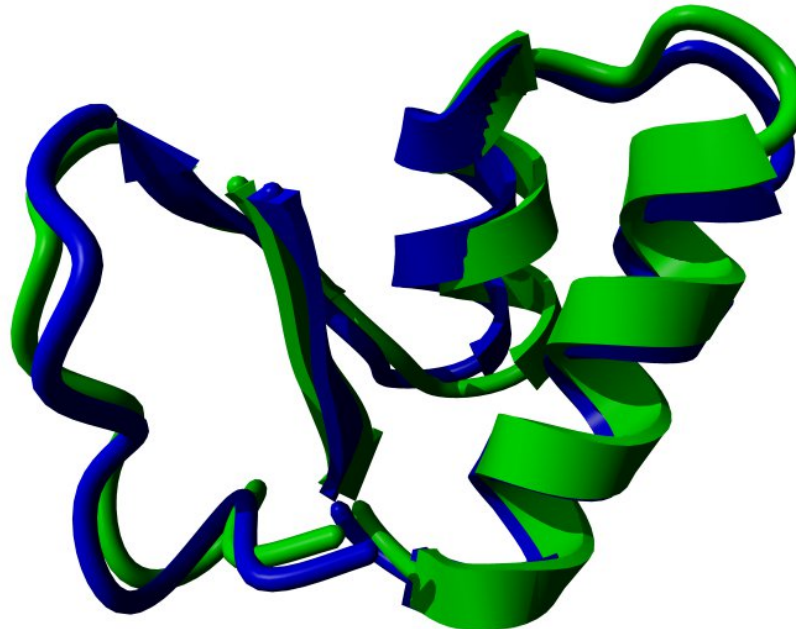
Identificeren van regio's die vergelijkbaar zijn als gevolg van een functionele, structurele of evolutionaire relatie.

Alignen van eiwitten

Dit zie je:

```
cram_craab: TTCCPSIVARSNFNVCRLPGTPEALCATYTGCIIPGATCPGDYAN  
thn_denc1 : KSCCPTTAARNQYNICRLPGTPRPVCAALSGCKIISGTGCPPGYRH
```

Maar eigenlijk doe je dit:



Pairwise alignment

Snel en simpel

Niet altijd betrouwbaar

score berekenen aan de hand van identities en similarities van de aminozuren.

```
AAB24882      TYHMCQFHCRYVNNHSGEKLYECNERSKAFSCPSHLQCHKRRQIGEKTHEHNQCGKAFPT 60
AAB24881      -----YECNQC GKAF AQHSSLKCHYRTHIGEKPYECNQC GKAFSK 40
                ****: .***: * *:* * :****. :* *****.

AAB24882      PSHLQYHERTHTGKPYECHQCGQAFKKCSLLQRHKRTHHTGKPYE-CNQC GKAF AQ- 116
AAB24881      HSHLQCHKRTHHTGKPYECNQC GKAF SQHGLLQRHKRTHHTGKPYMNVINMVKPLHNS 98
                **** *:*****:***:**. : *****: : *.: :
```

Pairwise alignment

Identity: Exact matches

Similarity (positives): vergelijkbare match (bv. R K)

```
AAB24882      TYHMCQFHCRYVNNHSGEKLIECNERSKAFSCPSHLQCHKRRQIGKTHEHNQCGKAFPT 60
AAB24881      -----YECNQCCKAFAQHSSLKCHYRTHIGKPYECNQCCKAFSK 40
                *****: .***: * *:* * :*****.:* *****..

AAB24882      PSHLQYHERTHTGKPYECHQCGQAFKKCSLLQRHKRTHGKPYE-CNQCCKAFAQ- 116
AAB24881      HSHLQCHKRTHGKPYECNQCCKAFSQHGLLQRHKRTHGKPYMNVINMVKPLHNS 98
                *****:*****:***:**.:*****:*****: *.::
```

Gaps en mismatches

Gaps (-) zijn belangrijk voor het beter alignen.

Ze simuleren indel events.

Een mismatch simuleert een substitutie

ATCGAT	ATCGAT	ATCGAT
ACGAT	ACGAT	A-CGAT

Gaps

Graag hebben we een alignment die evolutionair logisch is.

Wat is logischer?

```
ACGTCTGATACGCCGTATAGTCTATCT
ACGTCTGAT- - - - - - - - ATAGTCTATCT
```

```
ACGTCTGATACGCCGTATAGTCTATCT
AC - T - TGA - - CG - CGT - TA - TCTATCT
```

Een alignment score

De som van alle matches van een alignment, met gap penalties daarvan afgehaald.

Match score: +1

Mismatch score: 0

Opening gap penalty: -2

Lengte penalty: -1

Score?

```
ACGTCTGATACGCCGTATAGTCTATCT
||| - |||          || - ||| |||
ACGTTTGAT - - - - - - - - - - - ATACTCTATCT
```

Een alignment score

Match score: +1

Mismatch score: 0

Opening gap penalty: -2

Length penalty: -1

Score?

```
ACGTCTGATACGCCGTATAGTCTATCT
||| - |||          ||| - ||| |||
ACGTTTGAT - - - - - - - - A T A C T C T A T C T
```

$$\text{Score} = 18 - (2 + 6) = 10$$

Scoring systemen – PAM250

Bij het vergelijken van eiwitsequenties

- sommige aminozuren lijken meer op elkaar dan andere.

	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W
C	12																			
S	0	2																		
T	-2	1	3																	
P	-3	1	0	6																
A	-2	1	1	1	2															
G	-3	1	0	-1	1	5														
N	-4	1	0	-1	0	0	2													
D	-5	0	0	-1	0	1	2	4												
E	-5	0	0	-1	0	0	1	3	4											
Q	-5	-1	-1	0	0	-1	1	2	2	4										
H	-3	-1	-1	0	-1	-2	2	1	1	3	6									
R	-4	0	-1	0	-2	-3	0	-1	-1	1	2	6								
K	-5	0	0	-1	-1	-2	1	0	0	1	0	3	5							
M	-5	-2	-1	-2	-1	-3	-2	-3	-2	-1	-2	0	0	6						
I	-2	-1	0	-2	-1	-3	-2	-2	-2	-2	-2	-2	-2	2	5					
L	-6	-3	-2	-3	-2	-4	-3	-4	-3	-2	-2	-3	-3	4	2	6				
V	-2	-1	0	-1	0	-1	-2	-2	-2	-2	-2	-2	-2	2	4	2	4			
F	-4	-3	-3	-5	-4	-5	-4	-6	-5	-5	-2	-4	-5	0	1	2	-1	9		
Y	0	-3	-3	-5	-3	-5	-2	-4	-4	-4	0	-4	-4	-2	-1	-1	-2	7	10	
W	-8	-2	-5	-6	-6	-7	-4	-7	-7	-5	-3	2	-3	-4	-5	-2	-6	0	0	17

Scoring systemen – PAM250

Bij het vergelijken van eiwitsequenties

- sommige aminozuren lijken meer op elkaar dan andere.

	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W
C	12																			
S	0	2																		
T	-2	1	3																	
P	-3	1	0	6																
A	-2	1	1	1	2															
G	-3	1	0	-1	1	5														
N	-4	1	0	-1	0	0	2													
D	-5	0	0	-1	0	1	2	4												
E	-5	0	0	-1	0	0	1	3	4											
Q	-5	-1	-1	0	0	-1	1	2	2	4										
H	-3	-1	-1	0	-1	-2	2	1	1	3	6									
R	-4	0	-1	0	-2	-3	0	-1	-1	1	2	6								
K	-5	0	0	-1	-1	-2	1	0	0	1	0	3	5							
M	-5	-2	-1	-2	-1	-3	-2	-3	-2	-1	-2	0	0	6						
I	-2	-1	0	-2	-1	-3	-2	-2	-2	-2	-2	-2	-2	2	5					
L	-6	-3	-2	-3	-2	-4	-3	-4	-3	-2	-2	-3	-3	4	2	6				
V	-2	-1	0	-1	0	-1	-2	-2	-2	-2	-2	-2	-2	2	4	2	4			
F	-4	-3	-3	-5	-4	-5	-4	-6	-5	-5	-2	-4	-5	0	1	2	-1	9		
Y	0	-3	-3	-5	-3	-5	-2	-4	-4	-4	0	-4	-4	-2	-1	-1	-2	7	10	
W	-8	-2	-5	-6	-6	-7	-4	-7	-7	-5	-3	2	-3	-4	-5	-2	-6	0	0	17

CSTPAG

|+ |+|

CTWPGG

Score=


$$12+1-5+6+1+5=20$$

Multiple sequence alignment

Zwaar voor de computer

- Iedere sequentie met iedere andere sequentie alignen.
- Scores kunnen gebruikt worden voor een fylogenetische boom.

Betrouwbaarder: Meer informatie beschikbaar.



First 90 positions of a protein multiple sequence alignment of instances of the acidic ribosomal protein P0 (L10E) from several organisms. Generated with ClustalX.

Multiple sequence alignment

Meer sequenties meer informatie

CTGAGCGACGTAGCGCTCTTCGAGC

Multiple sequence alignment

Meer sequenties meer informatie

```
CTGAGCGACG TAGCGCTCTTCGAGC  
CTGAACGATT TAGCCATTTTCGAGC
```

Multiple sequence alignment

Meer sequenties meer informatie

```
CTGAGCGACGTAGCGCACTTCGAGC  
CTGAATGATTTAGGCATTTTCGAAT  
ATGCACTACTTAGTGATGGTCGTGT  
ATGCATGATGTAGCGATGGTCGACC
```

Waarom alignen?

Homologen vinden:

- Evolutionaire events identificeren.
 - Duplicaties
 - Soortvorming

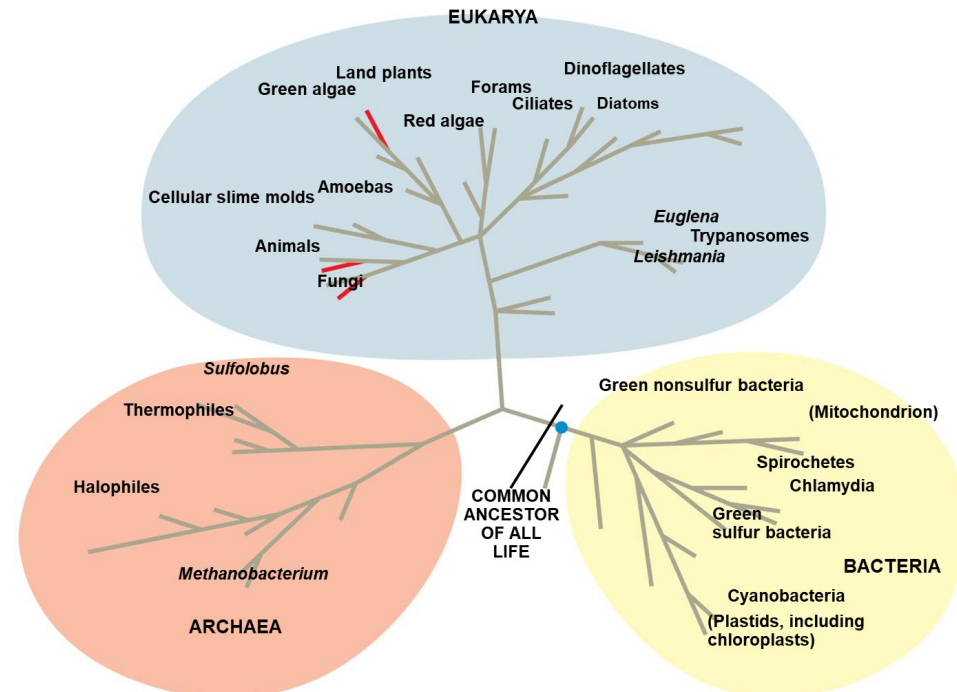
Extrapoleren van kennis over de ene sequentie naar een andere sequentie.

Waarom alignen?

Structuur en functie van een eiwit ontrafelen
Identificatie van geconserveerde sequenties.

Fylogenie

Identificeren van homologen, orthologen en paralogen



Homologen, paralogen en orthologen

Homologe sequenties

- Hebben een gemeenschappelijk vooroudersequentie

Homologen, paralogen en orthologen

“Muizen en ratten myoglobine zijn voor 98% homoloog.”

Homologen, paralogen en orthologen

“Muizen en ratten myoglobine zijn voor 98% homoloog.”

ONJUIST

Ze zijn homoloog of ze zijn het niet.

Homologen, paralogen en orthologen

Homologe sequenties

Waarschijnlijk homoloog als:

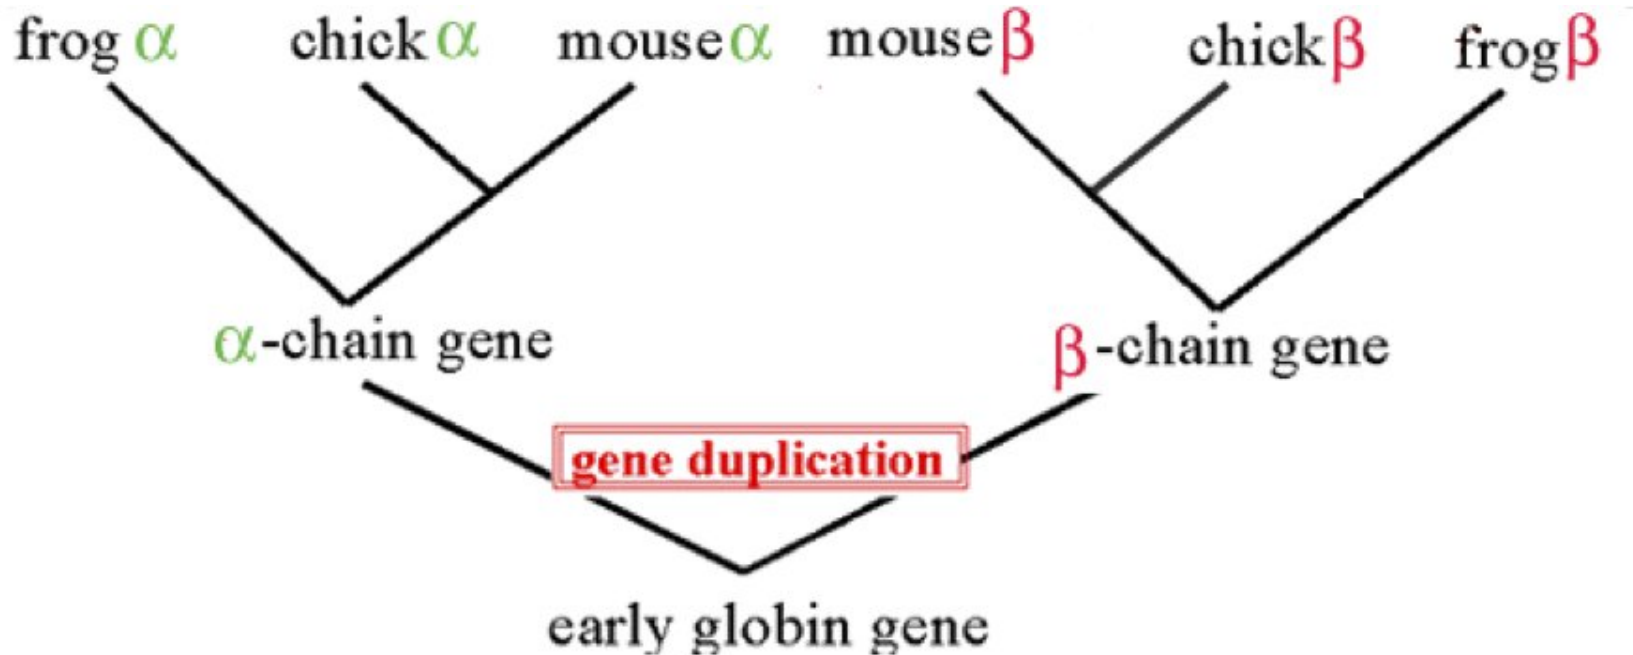
2 eiwitsequenties (>100 a.z.) >25% identiteit

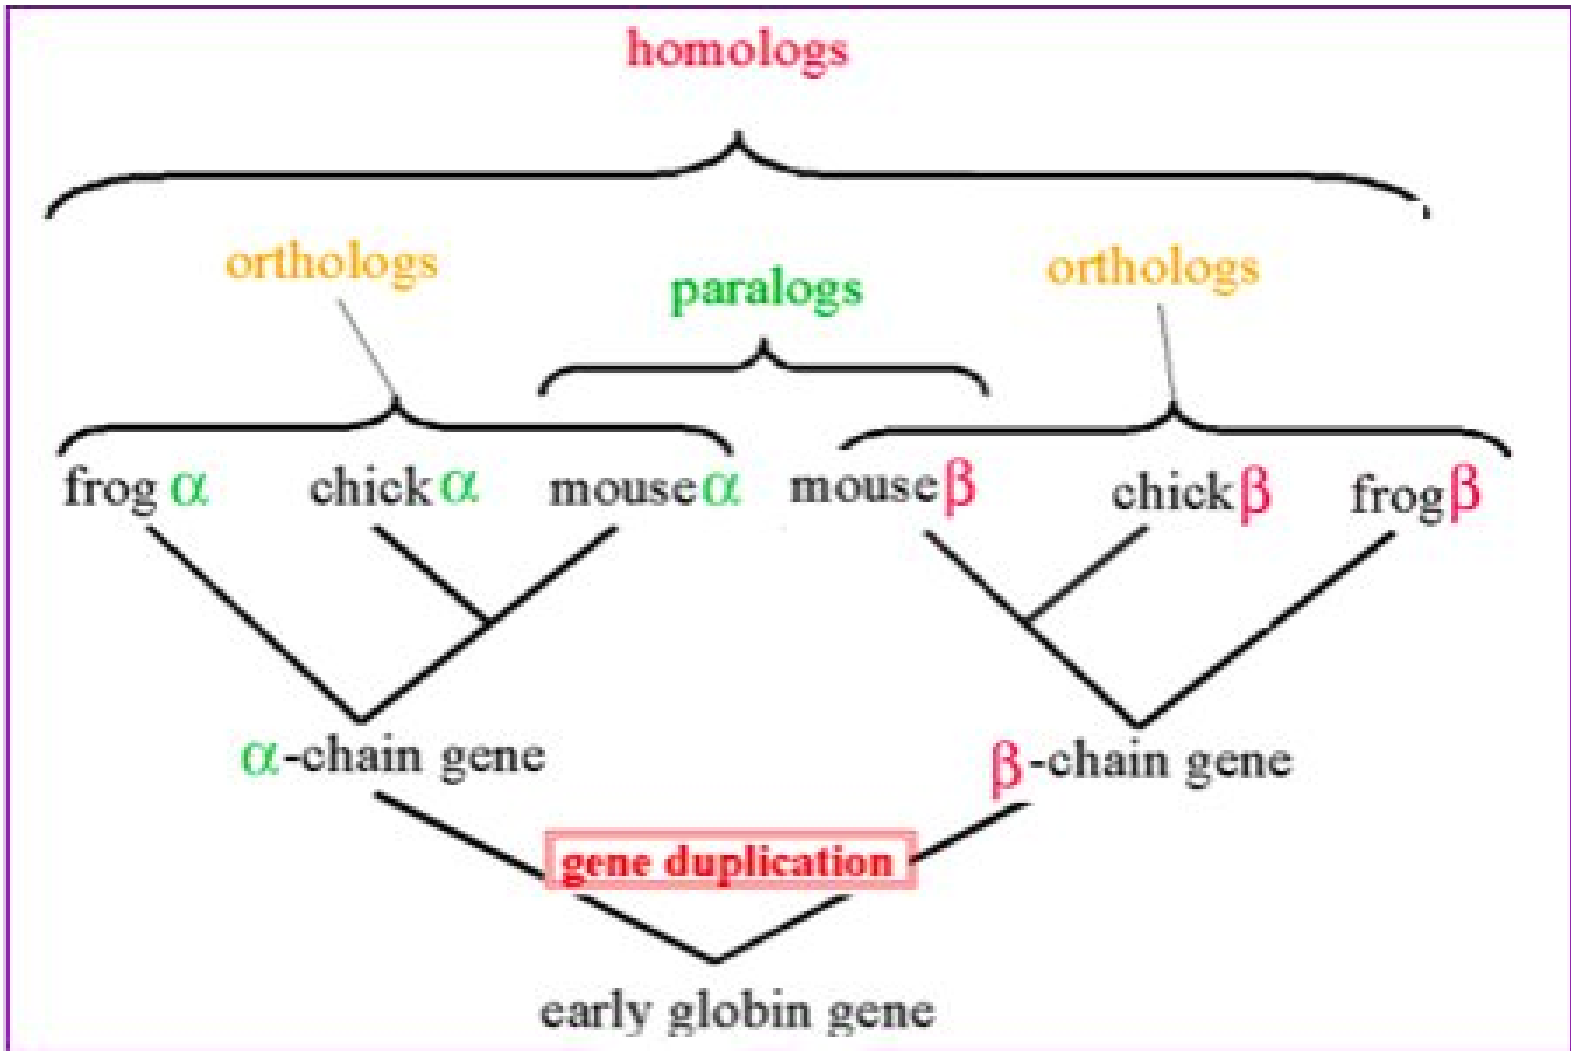
2 DNA sequenties (>100 nt) >70% indentiteit

Maar...

Bij een lagere identiteit kan er nog steeds sprake zijn van homologie.

Orthologs & Paralogs





BLAST

BLAST

- Onderzoeker kan een query sequentie vergelijken met een database van sequenties, en daarmee vergelijkbare sequenties identificeren.

Identificeren van paralogen en orthologen

Samenvattend

Alignen = Vergelijken van twee of meer DNA of eiwit sequenties.

Score matrix gebruiken we om de alignment te kwantificeren.

Alignen gebruiken we om orthologen en paralogen te vinden en om onze informatie over een sequentie te extrapoleren naar een andere sequentie.

Bronnen

Afbeeldingen afkomstig van:

Campbell – Biology A global Approach. 10/11th edition, Uitgever: Pearson
(Verplicht op de boekenlijst van de opleiding)

Lehninger- Principles of biochemistry, fifth edition. 2008 Uitgever W.H.
Freeman & co Ltd

<http://www.thegreatgoodplace.com/tt/attach/1/1205352441.gif>