

WS 2018/2019

„Genomforschung und Sequenzanalyse

- Einführung in Methoden der Bioinformatik-“

Thomas Hankeln

```
tctacggggccgtat  
||||||| |||||  
tctacggagctgtgt
```

Alignment von DNA- und Proteinsequenzen

...das vielleicht wichtigste Werkzeug der Bioinformatik!

Wozu Alignment?

- sind zwei Gene/Proteine miteinander verwandt?
> Phylogenie & Evolution
- Finde ich ähnliche/verwandte Sequenzen (z. B. aus einem anderen Organismus) in den Datenbanken?
> „gene discovery“
- besitzt mein Protein funktionelle Abschnitte (Domänen), die man bereits von anderen Proteinen her kennt?
> Funktion, Annotation

Biologie ist eine komparative Wissenschaft!



?



...nicht jedes Sprichwort stimmt!

...Bioinformatik & Genomforschung sind es auch!

Query: 1 tctacggggccgtagtgcaggccatgagtcgaggctggatggcgagtaagag 53
Sbjct: 616 tctacggagctgtqgtqcaqccatqagc~~q~~gaggctggacggggagtaaqag 668

Nt-Substitution

As-Austausch/ replacement

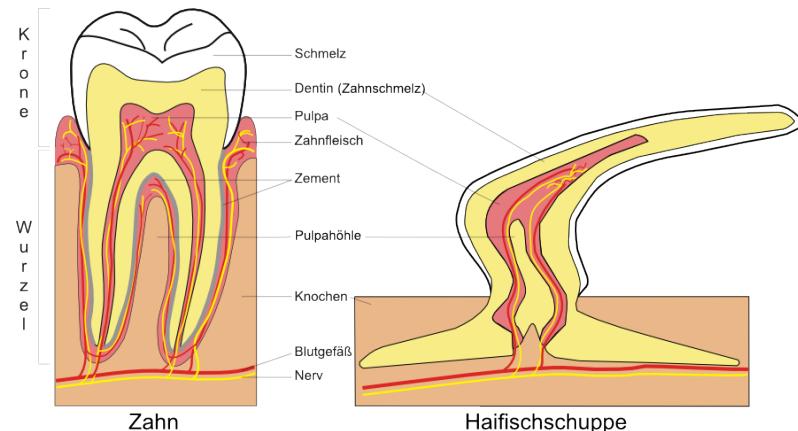
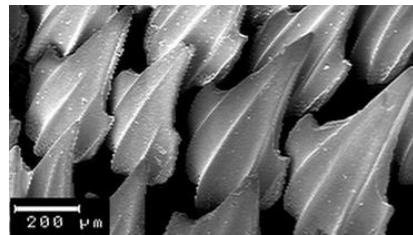
Query: 5 EPELIQSWRAVSRSPLEHGTVLFARLFALEPDLLPLFQY--NCRQFSSPEDCLSSPEFL 62
+ ELIR SW ++ ++ + HG +LF+RLF L+P+LL LF Y NC S +DCLSSPEFL
Sbjct: 8 DKELIRGSWDSLGNKVNPHGVILFSLFELDPELLNLFHYTTNC---GSTQDCLSSPEFL 64

Gap bzw. InDel

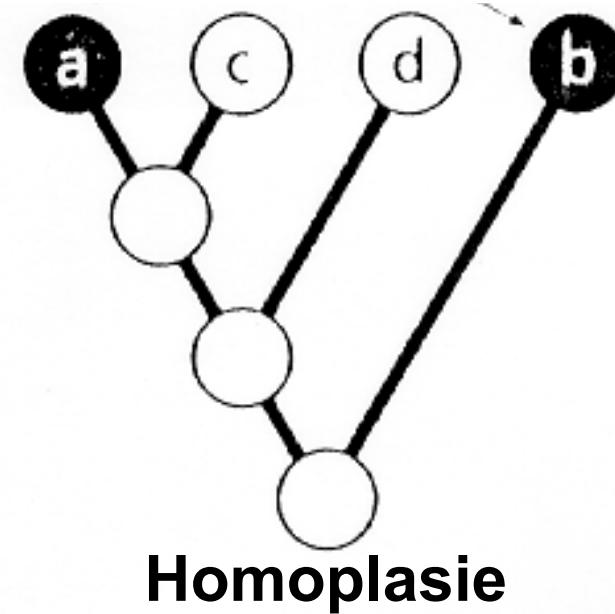
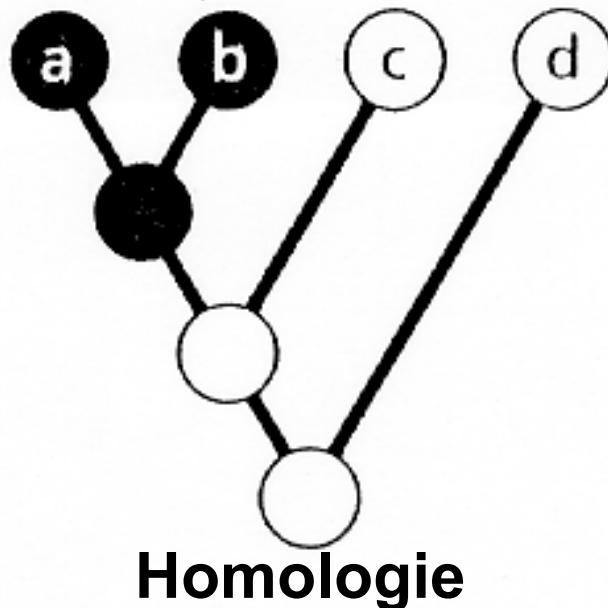
ähnliche As

identische As

Welche Vergleiche mache Sinn?



Homologie !!!



- Merkmal ‚Schwarz‘ von **gemeinsamem Vorläufer** geerbt

- Merkmal ‚Schwarz‘ **konvergent** aus ‚weißen‘ Vorläufern entstanden

Welche Vergleiche mache Sinn?

YWRED~~F~~GINSHHWHWHLVYPI
 YWREDYGINVHHWHWHLI~~Y~~PP~~E~~
 YFREDIGINLHHWHWHLVY~~P~~E
 YFREDIGVNSHHWHWHLVY~~P~~T
 YFREDLGINLHHWHWHLVY~~P~~E
 YFREDLGVNLHHWHWHLVYPI
 YFREDIGVNAHHWHWHV~~V~~YPS
 YFREDIGINSHHWHWHLVY~~P~~A
 YFREDIGANAHHWHWHI~~V~~Y~~P~~E
 YYREDVGINAHHWHWHLVYPS
 YFGEDIGLNTHHVTWHMEF~~P~~E
 YFGEDVGMNTHHVLWHMEF~~P~~E
 YFGEDIGMNIHHVTWHMDF~~P~~E

IEM-----NVN
 PAM-----GFD
 FDAADRA-IVN
 TTGPTE--VVN
 FEASDRS-IVA
 IEAPDRS-IVD
 STYDPAFFGKV
 AFYDADIFGKI
 PTWDASVMSKV
 STWNPKYFGKK
 FWWNDAYG-HH
 FWWEDSSG-RH
 FWWEDSYG-YH

VN~~L~~NRVEKLE
 LGLPKVEKLD
 NNLSRVRRYN
 NNLKVKQPLN
 NNLARVLPFN
 NHMARVQPFN
 NGLNRMIPFH
 VGLQRMIPFQ
 TGLRRMIPFH
 NGMHRMLPFN
 NYLD~~P~~VGE~~L~~
 NHLD~~P~~VEELS
 NWLD~~P~~VDELH

?

PlePPO	YWRED F GINSHHWHWHLVYPI	EM-----NVNR	DRKGELFY Y MHQQMVAR	YDWERLSVN	LN R VEKLE	61
PmOPPO	YWREDYGINVHHWHWHLI Y PP	PAM-----GFD	DRKGELFY Y MHQQMVAR	YDIERL	CLGLPKVEKLD	61
BmOPPO1	YFREDIGINLHHWHWHLVY	PFDAADRA-IVN	KDRRGELFY Y MHQQMVAR	YDIERL	CLGLPKVEKLD	65
Dm E PP0A1	YFREDIGVNSHHWHWHLVY	PTTGPTE--VVN	KDRRGELFY Y MHQQMVAR	YDIERL	CLGLPKVEKLD	64
Dm E PP02	YFREDLGINLHHWHWHLVY	PFEASDRS-IVAK	DRRGELFY Y MHQQMVAR	YDIERL	CLGLPKVEKLD	65
Dm E PP03	YFREDLGVNLHHWHWHLVY	IEAPDRS-IVD	DRRGELFY Y MHQQMVAR	YDIERL	CLGLPKVEKLD	65
EcaHcA	YFREDIGVNAHHWHWHV V Y	STYDPAFFGKV	DRKGELFY Y MHQQMVAR	YDCERLSN	GLNRMIPFH	66
EcaHcD	YFREDIGINSHHWHWHLVY	AFYDADIFGKI	DRKGELFY Y MHQQMVAR	YDCERLSV	GLNRMIPFQ	66
EcaHcF	YFREDIGANAHHWHWHI V Y	PPTWDASVMSKV	DRKGELFY Y MHQQMVAR	YDCDRLSTGL	RRMIPFH	66
LpoHc2	YYREDVGINAHHWHWHLVY	STWNPKYFGKK	DRKGELFY Y MHQQMVAR	YDCERLSN	GMHRMLPFN	66
PvaHc	YFGEDIGLNTHHVTWHMEF	PPFWNDAYG-HH	DRKGENDFWIHHQLTVRFDA	YERLSNYLD	PVGE L	65
PirHcC	YFGEDVGMNTHHVLWHMEF	PFWWEDSSG-RHL	DRKGESFFWVHHQLTVRYDA	YERLSNHLD	PVVEELS	65
PirHcA	YFGEDIGMNIHHVTWHMDF	PFFWEDSYG-YHL	DRKGELFFWVHHQLTARFDF	YERLSNWLD	PVDELH	65

‘twilight zone’

Sequence Name	< Pos = 1
-	
<input checked="" type="checkbox"/> Consensus	MVLSAADKGAVTAWGKVGGKAREYGGGEALGRLLVVFPTTQFFESFGDLSTGSAVMNNPQVKGHGAKVAAALSN
2 Sequences	10 20 30 40 50 60 70
hbbbov	M-LTAEKKAATVAFWGKV--KVDEVGGEALGRLLVVPWTQRFESFGDLSTADAVMNNPKVKAHGKKVLDGSNG
HBAbov	MVLSAADKGKGNVKAAGKVGGHAREYGAEARLMFLSFPTTKTVFPHF-DLSHGS-----QVKGHGAKVAAALT

Hb b
Hb a

Sequence Name	< Pos = 1
-	
<input checked="" type="checkbox"/> Consensus	M---XLX---AAXKAXVXAXWGVXXXXDEVGGEALGRLXXVFPXTXXXFXXDLSXXD---AXXXXXXVXHGXX
3 Sequences	10 20 30 40 50 60 70
hbbbov	M----LT---AEEKAATVAFWGKV--KVDEVGGEALGRLLVVPWTQRFESFGDLSTAD--AVMNNPKVKAHGKK
HBAbov	M---VLS---AADKGKGNVKAAGKVGGHAREYGAEARLMFLSFPTTKTVFPHF-DLSHGS---A-----QVKGHGAK
chirohb3	MKFLILALCFAAASALSADQISTVQASFDKVKGDPVGILYAVFKADPSIMAKFTQFAGKQLESIKGTAPFEIHANR

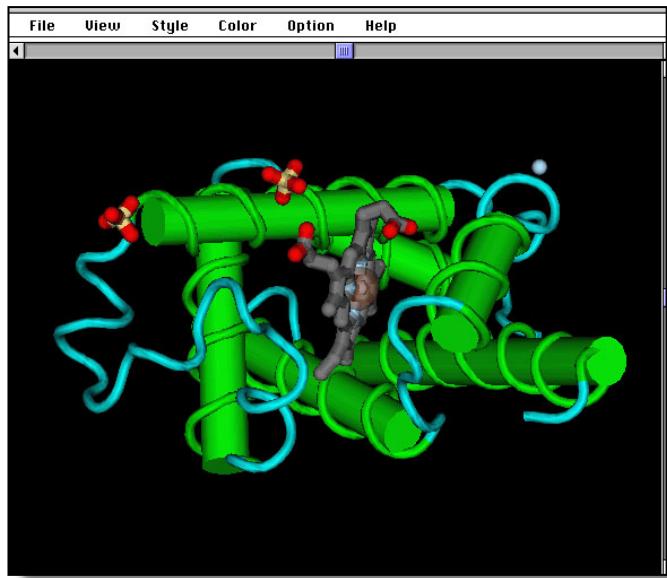
Hb b
Hb a
Mücken-Globin

Sequence Name	< Pos = 1
-	
<input checked="" type="checkbox"/> Consensus	MVLSAASKGNVKGAWGEVGGQARRYGGGEALEDNRLSKEEFPAVKPSTYFGQLDLLEGSGQVLGQGAAVAAALAKAV
2 Sequences	10 20 30 40 50 60 70
F11G11-1.2	MVHYKVSFPTRGA-GETIARQILAYAGQDFEDNRIPKEEWPAPVKPSTPFQQLPLLEVDGKVLAQSHAIRARYLARQF
HBAbov-1.	MVLSAADKGKGNVKAAGKVGGHAREYGAEARLMFLS---FPTTK--TYFPHFDLSHGSQVKGHGAKVAAALT

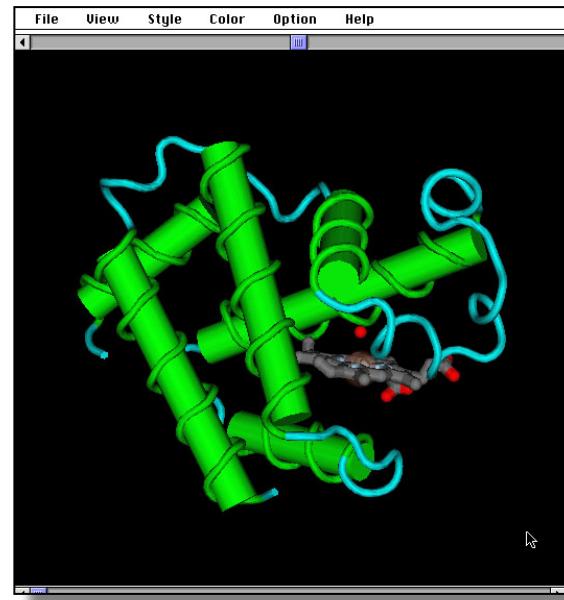
Glutathion-
S-Transferase
Hb a

Die interessantesten Erkenntnisse sind oft dort zu finden,
wo die Alignments schwierig und zweideutig sind

Sequenzen vs. Proteinstruktur



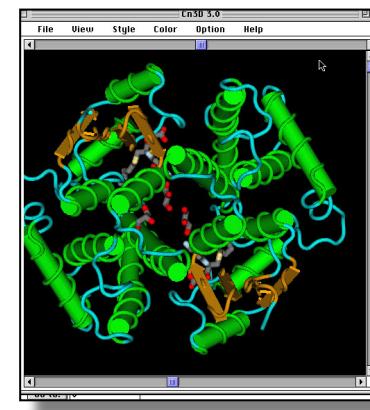
Myoglobin



Mücken Globin

Trotz großer Veränderungen der Aminosäuresequenz kann die 3D-Struktur konserviert sein!

Aber:



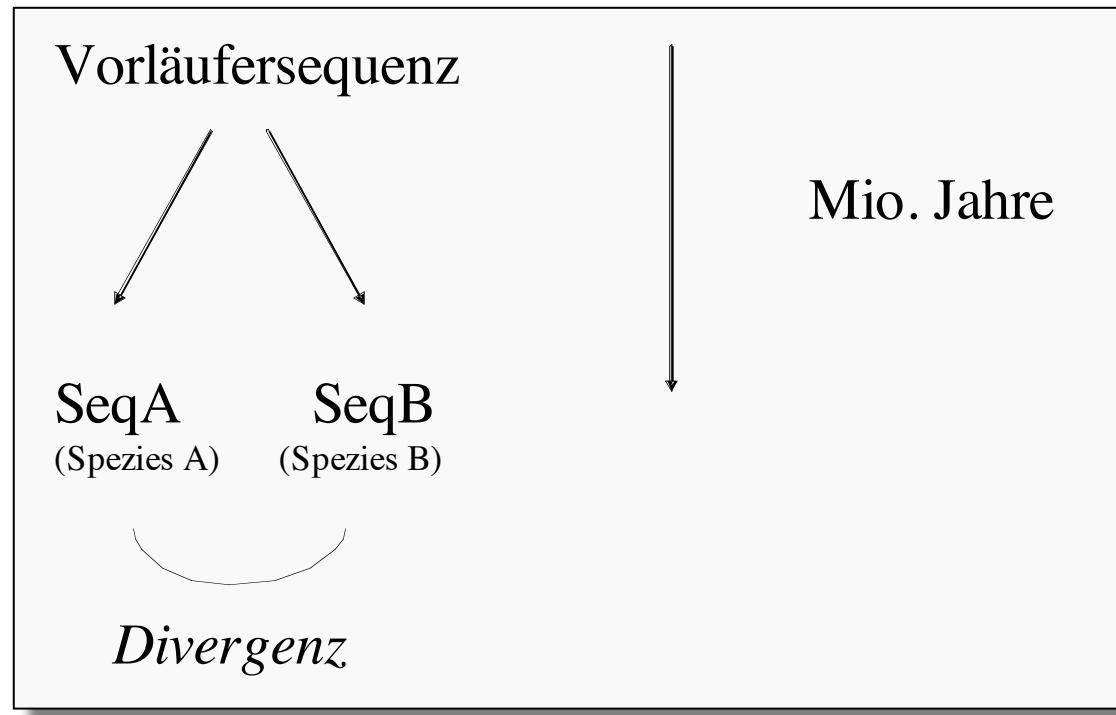
Glutathion-S-Transferase



**Nothing in Biology Makes Sense
Except in the Light of Evolution!**

Theodosius Dobzhansky (1900-1975)

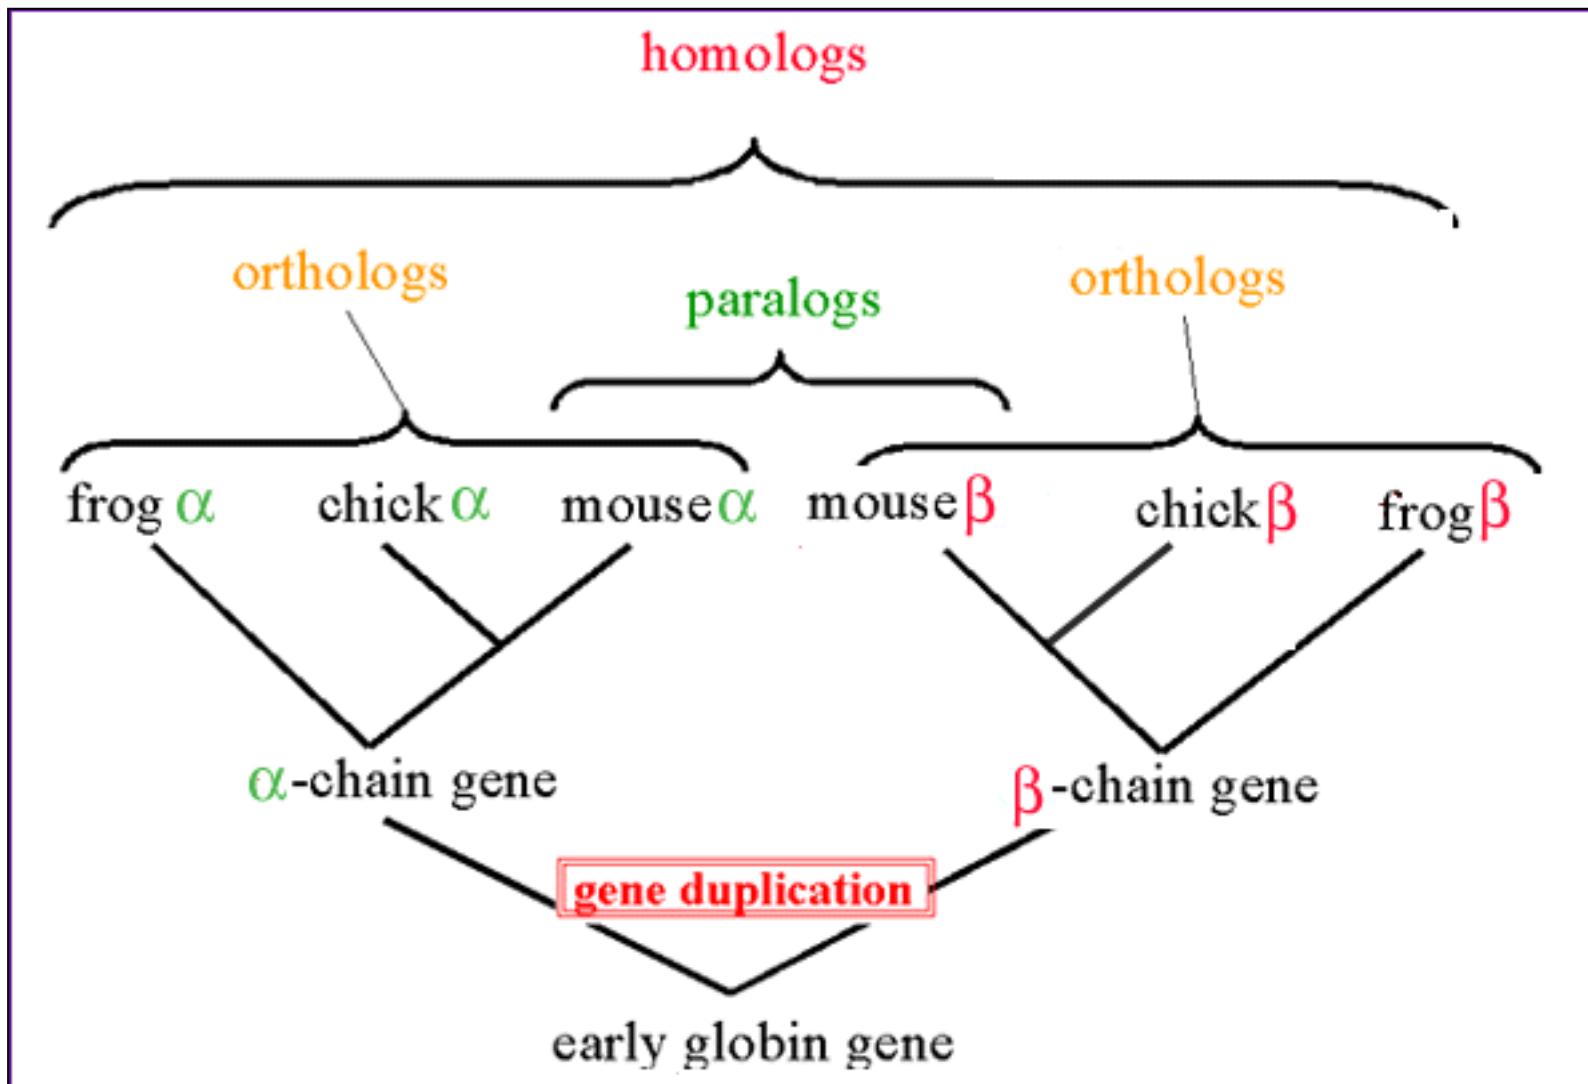
Alignments reflektieren die Evolution !!!!



Sind die zu alignierenden Sequenzen aus einer **gemeinsamen Vorläufersequenz** hervorgegangen?

Beim Erstellen und Bewerten von Alignments konstruieren wir evolutionäre Hypothesen!

Bei Genen: Paralog vs. Ortholog



Homologie, Identität, Ähnlichkeit

Beim Vergleich zwischen DNA-Sequenzen oder Proteinsequenzen sprechen wir zunächst immer von

- **Sequenzübereinstimmung (identity) oder**
- **Sequenzähnlichkeit (similarity)**

Erst aus diesem Vergleich heraus können wir überlegen, ob die gefundenen Übereinstimmungen wirklich **homolog** sind!

Protein-Sequenzen: Identität & Ähnlichkeit

```
Score = 91.3 bits (223), Expect = 4e-18
Identities = 59/156 (37%), Positives = 88/156 (55%), Gaps = 14/156 (8%)
```

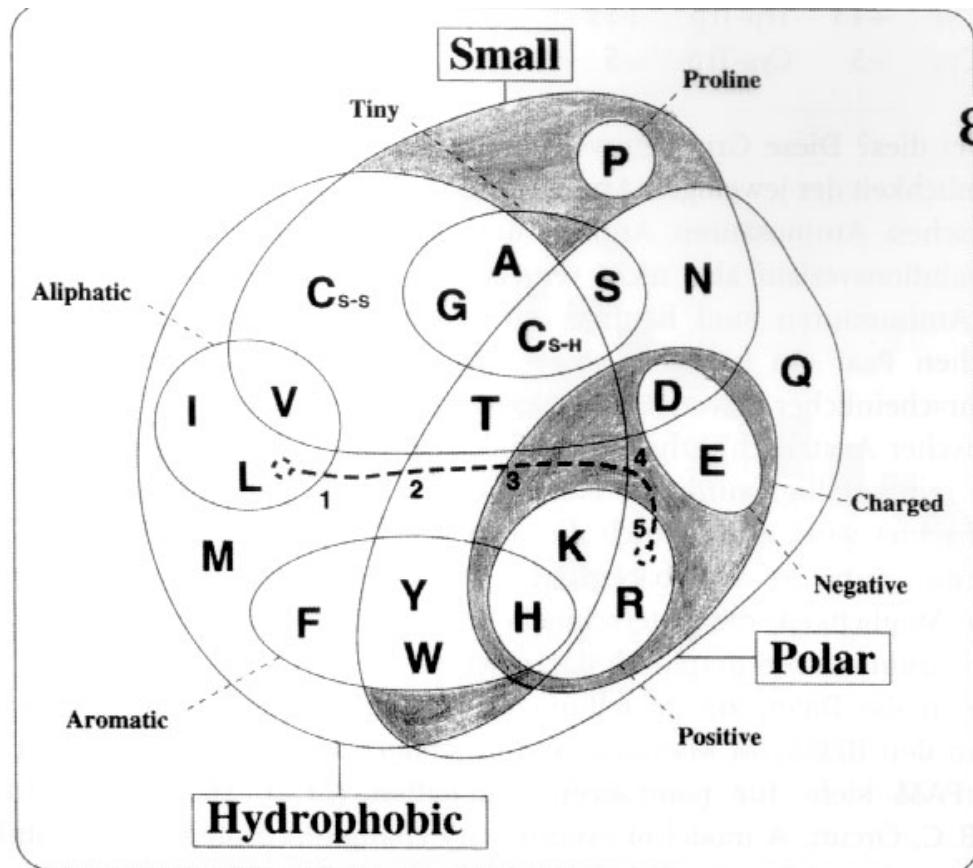
```
Query: 4  MYKKILYPTDFSETAEIALKHVKAFKTLKAEEVILLHVIDEREIKKRDIFSLLLGVAGLN 63
          +YKKI+ PTD S+ + A KH           EV  ++V+D           S  +G+
Sbjct: 25 LYKKIVIPTDGSDVSLEAAKHAINIAKEFDAEVYAIYVVD-----VSPFVGLPA-- 73

Query: 64  KSVEEFENELKNKLTEEAKNKMENIKKELEDVGFKVKDIIIVVGIPHEEIVKIAEDEGVDI 123
          +   E  +EL  L  EE +  ++  +KK  E+  G  K+  ++  G+P  EIV+  AE +  D+
Sbjct: 74 EGSWELISEL---LKEEGQEALKVKVKMAEEWGVKIHTEMLEGVPANEIVEFAEKKKADL 130

Query: 124 IIMGSHGKTNLKEILLGSVTENVVIKKSNKPVLVVKR 159
          I+MG+  GKT L+  ILLGSV  E  VIK  ++  PVLVVK+
Sbjct: 131 IVMGTTGKTGLERILLGSVAERVIKNAHCPVLVVKK 166
```

Bei Proteinsequenz-Alignments unterscheidet man
Sequenzidentität und **Sequenzähnlichkeit**
(= Identität plus iso-funktionelle As)

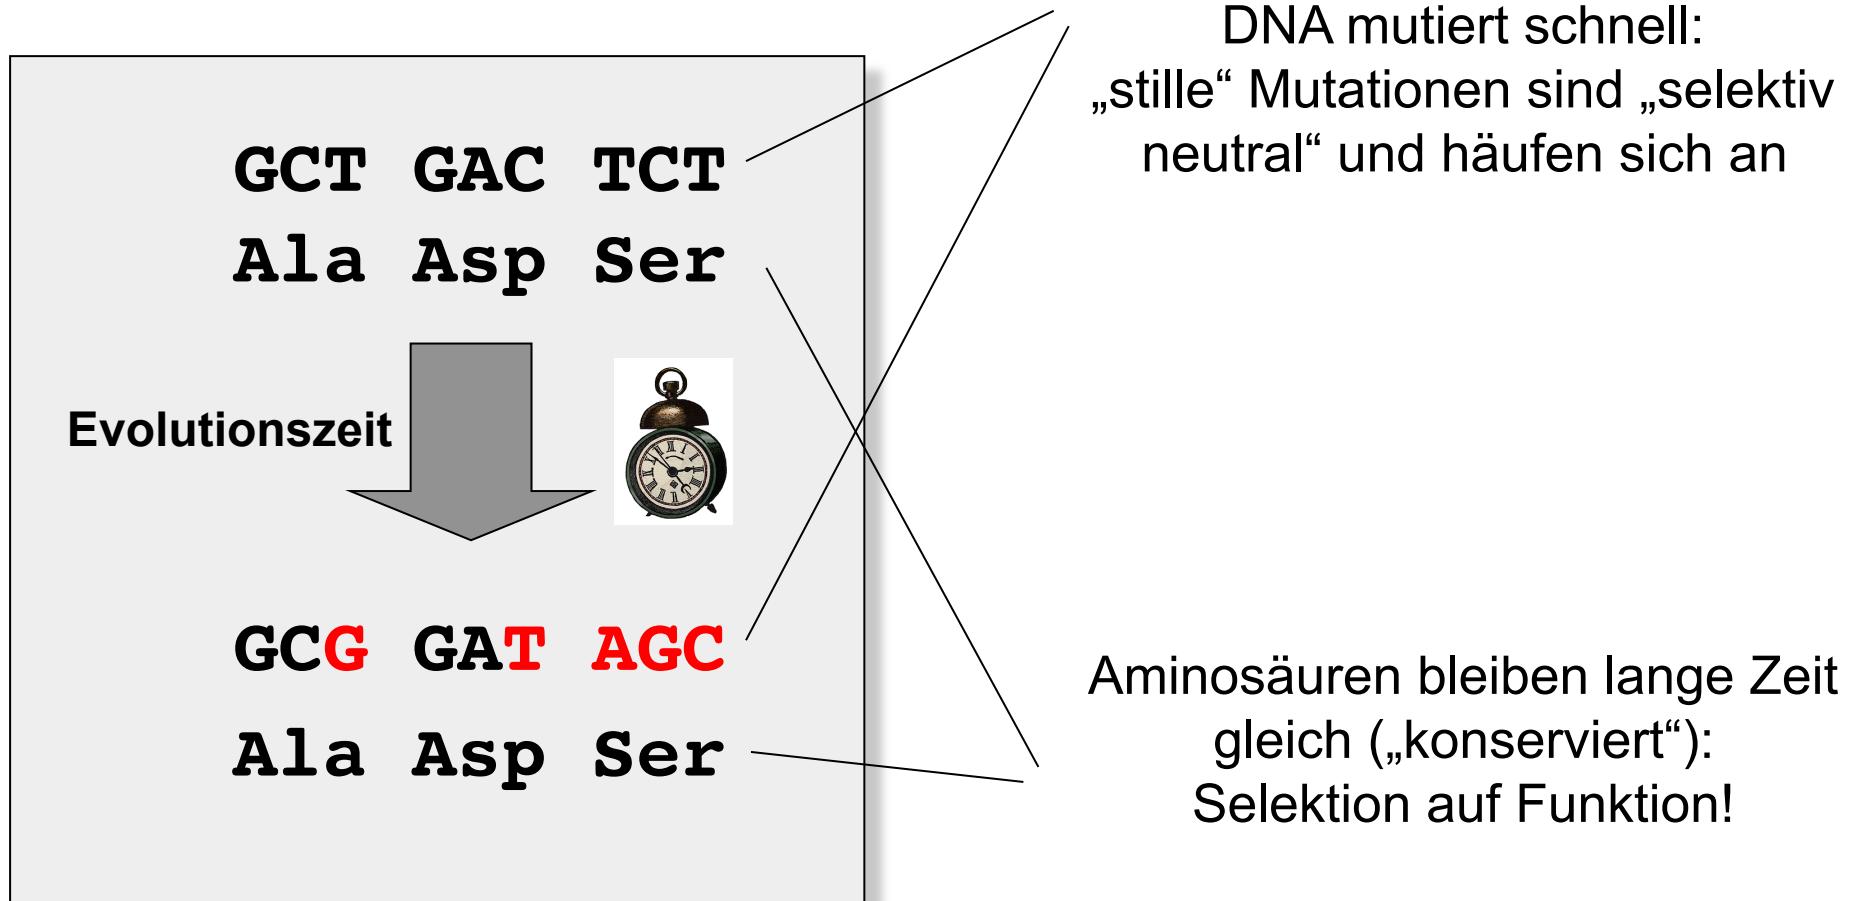
Funktionelle Ähnlichkeit von Aminosäuren



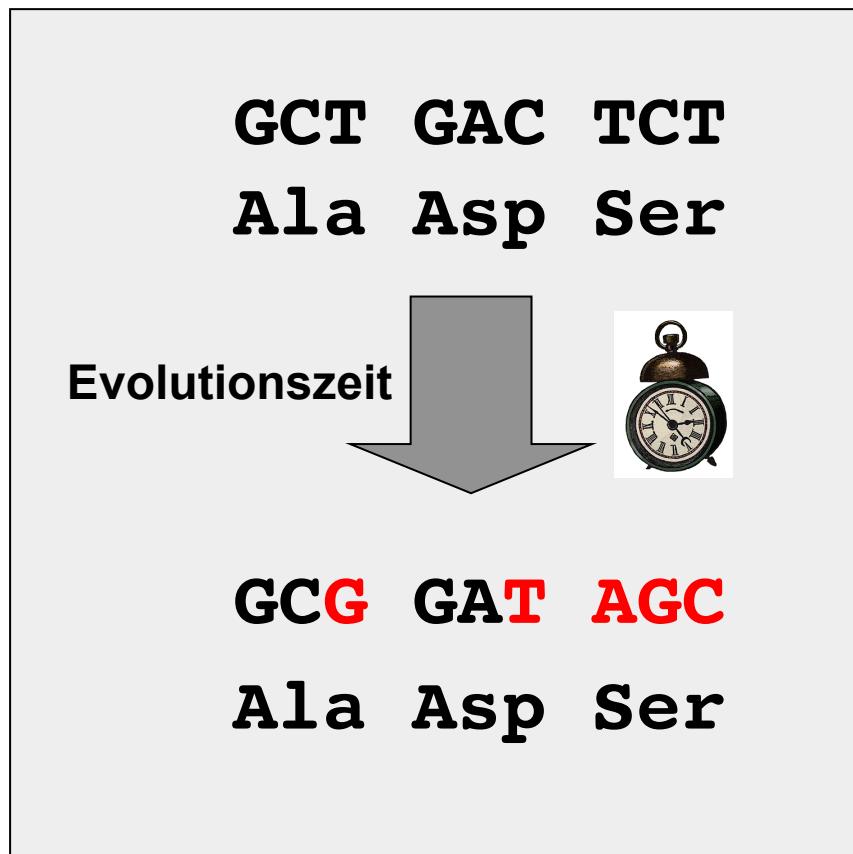
1.29 Dieses Diagramm ist eine recht anschauliche Weise, den unterschiedlichen Grad von Ähnlichkeit zwischen Aminosäuren zu verdeutlichen. Die 20 natürlichen Aminosäuren werden durch ein Set von 10 physiko-chemischen Eigenschaften beschrieben und den überlappenden Sektoren zugeordnet. So ist z. B. Lysin (K) positiv, geladen, polar und hydrophob. Zur Bewertung des Konservierungsgrades einer Position in einem Alignment wird deren Konservierungsnummer C_n berechnet: $C_n = 10 - P$, mit P als der Anzahl der Sektorenüberschritte, die über-

schritten werden müssen, um alle Aminosäuren dieser Alignmentposition zu erreichen und 10 der Gesamtzahl von Eigenschaften. Ist z. B. eine Alignmentposition (Säule) nur von L und R besetzt, so müssen für eine solche Substitution fünf Sektorenüberschritte überschritten werden: $C_n = 10 - P = 5$ (aus Livingstone, Barton, in: *Methods in Enzymology*, Vol. 266: *Computer Methods for Macromolecular Sequence Analysis*, R. F. Doolittle, ed., pp. 497–512. Abdruck mit Genehmigung von Academic Press).

Vergleiche ich auf DNA- oder auf Protein-Ebene?

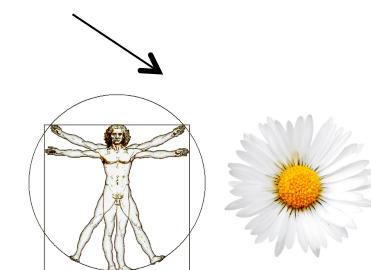


Vergleiche ich auf DNA- oder auf Protein-Ebene?



Konsequenz:

- Suche auf **DNA-Ebene** funktioniert gut zwischen **nahe verwandten Taxa oder Genen**
- Suche auf **Aminosäureebene** kann auch noch Ähnlichkeiten von **entfernt verwandten Sequenzen** detektieren

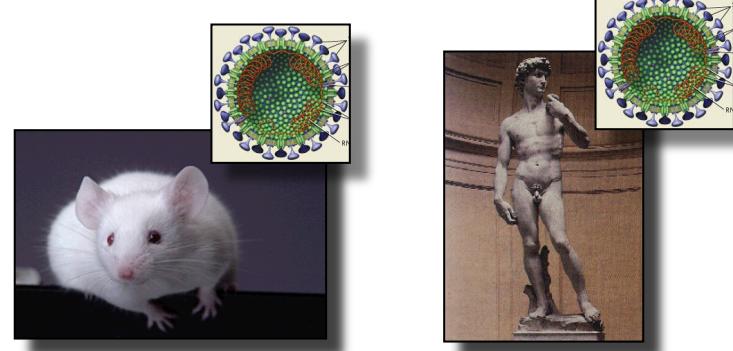


Alignment:

Wann DNA? Wann Protein?



**Eng verwandte SARS-Varianten
in der Population**



**Corona-Virus-Gruppen
aus verschiedenen Spezies**

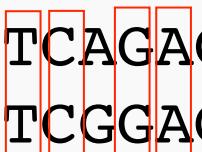
Warum ist es nicht einfach, das „beste“ Alignment zu konstruieren?

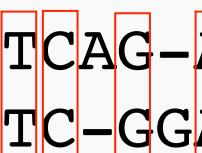
- 2 Sequenzen à 300 Bp
= 10^{88} mögliche Alignments!!!
- Computer-Algorithmen erforderlich, die ohne Ausprobieren aller Möglichkeiten auskommen.
- „**Regelwerk**“ notwendig, um bestmögliches Alignment zu erkennen

Warum ist es nicht einfach, das „beste“ Alignment zu konstruieren?

seqA	TCAGACGATTG (11)
seqB	TCGGAGCTG (9)

I. TCAG-ACG-ATTG
 TC-GGA-GC-T-G

II. TCAGACGATTG
 TCGGAGCTG--

III. TCAG-ACGATTG
 TC-GGA--GCTG

Annahmen über den Ablauf
der Sequenz-Evolution:

I. Keine mismatches

II. Keine internen Lücken

III. „Von beidem Etwas“

20

Aber was ist richtig?

(manchmal)

...etwas einfacher geht's mit dem 20 As-Alphabet von Proteinen

Finde das optimale Alignment:

THIS IS A RATHER LONGER SENTENCE THAN THE NEXT
THIS IS A SHORT SENTENCE

THIS IS A RATHER LONGER - SENTENCE THAN THE NEXT
| | | | | --*| -- -| ---| - | | | | | | | ----- ----- -----

THIS IS A --SH-- -O---R T SENTENCE ----- ----- -----

or

THIS IS A RATHER LONGER SENTENCE THAN THE NEXT
| | | | | ----- ----- | | | | | | | ----- ----- -----

THIS IS A SHORT- ----- SENTENCE ----- ----- -----

Warum ist ein „richtiges“ Alignment so problematisch?

- Zwei beliebige Sequenzen lassen sich prinzipiell **immer** alignen!
- Es gibt **viele mögliche Alignments**
- Sequenz-Alignments müssen also in ihrer ‚Güte‘ bewertet werden, um das ‚**optimale Alignment**‘ zu finden
- Häufig wird es mehrere **gleich gute Lösungen** geben

ACGTACGTACGTACGTACGTACGTACGT
| | | | | | | | | | | | | | | | | | | |
GATCGATCGATCGATCGATCGATCGATCGATC

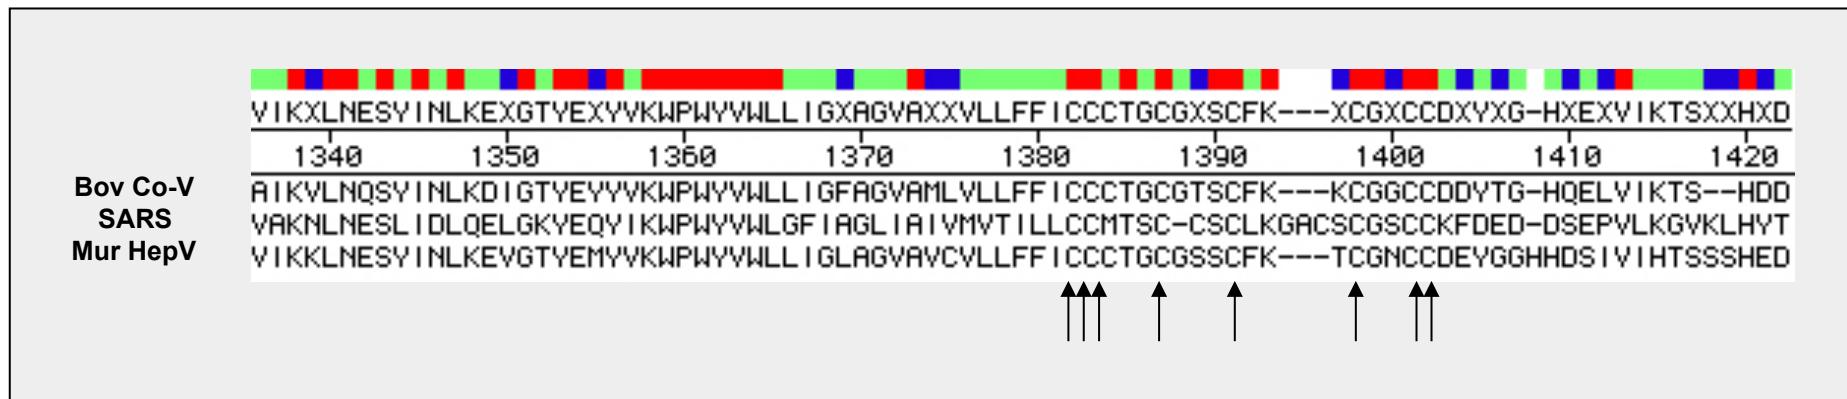
ACGTACGTACGTACGTACGTACGTACGTACGT
| | | | | | | | | | | | | | | | | | | |
GATCGATCGATCGATCGATCGATCGATCGATC

Wie erstellt man ein möglichst „richtiges“ Alignment ?

Wir brauchen „**evolutionäre Modelle**“, um die beobachteten Sequenzveränderungen richtig zu bewerten:

- wie häufig mutiert ein A nach G bzw. nach C od. T (Transitionen : Transversionen)?
- wie häufig entstehen In/Dels relativ zu Substitutionen?
- wie häufig wird während der Proteinevolution eine Aminosäure durch irgendeine andere Aminosäure ersetzt?

Was bedeutet es, ein „Evolutionsmodell“ zu haben?



Ein „Evolutionsmodell“ basiert auf empirischen Daten! Zum Beispiel:
Ich weiß, die Aminosäure Cystein ist für die Proteinstruktur äußerst wichtig!

- Cysteine sind also **konserviert** während der Evolution von Proteinen!
- Cysteine können daher beim Alignment zweier Proteinsequenzen als **Ankerpunkte** dienen
- ein Alignment mit übereinanderstehenden Cysteinen würde danach mit Pluspunkten **belohnt**

Ein Alignment ist

Es gibt kein „richtiges“ Alignment, sondern nur.....

Um die Qualität eines Alignments zu bewerten, brauche ich

Um zu verhindern, dass ein unsinniges Alignment gemacht wird, muss ich verhindern, dass

**...zunächst zur Behandlung
von Lücken!**



Ein einfacher Score-Wert zur Bewertung eines Alignments...

$$S = Y - \sum W_k$$

S = Similarity-Score

Y = Anzahl an Matches

W_k = **gap penalty** für gaps der Länge k

Das Setzen einer Lücke wird durch einen negativen Score (**gap penalty**) bestraft!

Gap-Penalty

Mit Setzen der **gap penalty** trifft man Annahmen über die relative Häufigkeit von indel-Mutationen während der Evolution!

- gap **opening** penalty
 - ...Kosten für das Setzen einer Lücke
- gap **extension** penalty
 - ...Kosten für die Verlängerung einer Lücke

Gap-Penalty

- „lineare“ gap penalty:

$$W = (d \cdot g) \quad \text{mit } g = \text{gap-Länge}$$

und $d = \text{gap opening penalty}$

> nimmt an, dass gaps umso unwahrscheinlicher sind, je länger sie erscheinen (macht lange gaps unnötig „teuer“)

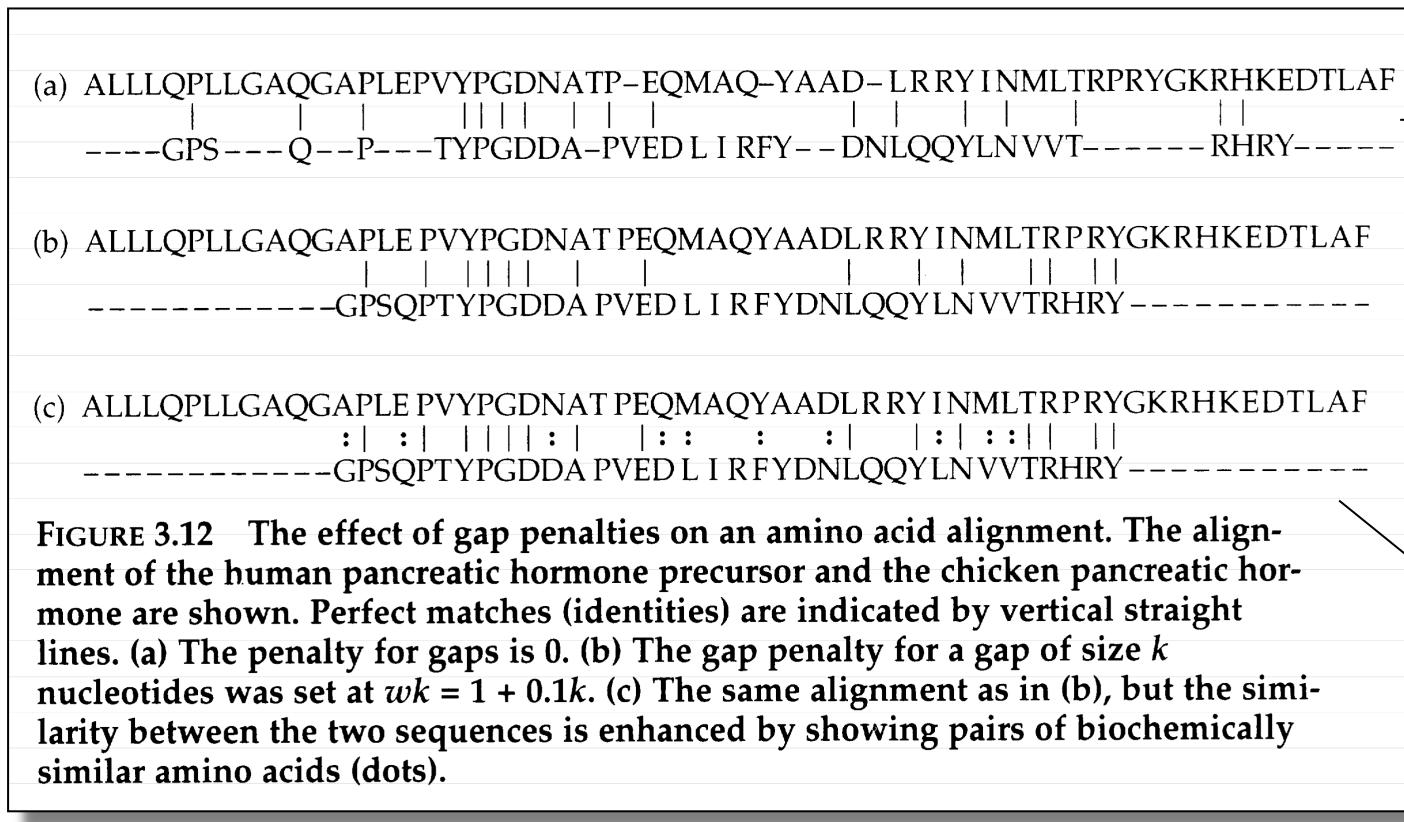
- „affine“ gap penalty:

$$W = (d + g \cdot e) \quad \text{mit } e = \text{gap extension}$$

penalty ($e < d$)

> lange Indels werden weniger bestraft als bei linearer Gap penalty. Man nimmt dann an, dass z. B. gaps von der Länge 1 oder der Länge 10 nicht drastisch unterschiedlich häufig während der Evol. entstehen

Auswirkungen der gap penalty



Penalty = 0

Penalty
 $w_k = 1 + 0.1k$

Anzeigen der
biochemisch ver-
wandten As macht
deutlich, daß das
Alignment (b) Sinn
macht

FIGURE 3.12 The effect of gap penalties on an amino acid alignment. The alignment of the human pancreatic hormone precursor and the chicken pancreatic hormone are shown. Perfect matches (identities) are indicated by vertical straight lines. (a) The penalty for gaps is 0. (b) The gap penalty for a gap of size k nucleotides was set at $w_k = 1 + 0.1k$. (c) The same alignment as in (b), but the similarity between the two sequences is enhanced by showing pairs of biochemically similar amino acids (dots).

...und jetzt zu den Austauschen!

- in sog. „Substitutionsmatrizen“ wird die relative Häufigkeit erfasst, mit der Nukleotide oder Aminosäuren während der Evolution ausgetauscht werden.

Eine einfache Identitätsmatrix bei Nukleotidsequenzen...

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

- alle Richtungen von Nt-Austauschen sind gleich wahrscheinlich
- bei jedem „match“ beider Sequenzen gibt es 1 Punkt für den Übereinstimmungs-Score

DNA-Alignment-Bewertung

seqA	TCAGACGATTG (11)
seqB	TCGGAGCTG (9)

I. TCAG-ACG-ATTG
 TC-GGA-GC-T-G

$$D = 7 - 6(3+1 \times 0.1) = - 11.6$$

II. TCAGACGATTG
 TCGGAGCTG--

$$D = 4 - (3+2 \times 0.1) = + 0.8$$

III. TCAG-ACGATTG
 TC-GGA--GCTG

$$D = 6 - 2(3+1 \times 0.1) - (3+2 \times 0.1) = - 3.4$$

Match = +1

Gap-Parameter:

d = **3** (gap opening)
e = 0.1 (gap extension)

Bei **hoher** gap opening penalty!

DNA-Alignment-Bewertung

seqA	TCAGACGATTG (11)
seqB	TCGGAGCTG (9)

I. TCAG-ACG-ATTG
 TC-GGA-GC-T-G

?

II. TCAGACGATTG
 TCGGAGCTG--

III. TCAG-ACGATTG
 TC-GGA--GCTG

Match = +1

Gap-Parameter:

d = 1 (gap opening)

e = 0.1 (gap extension)

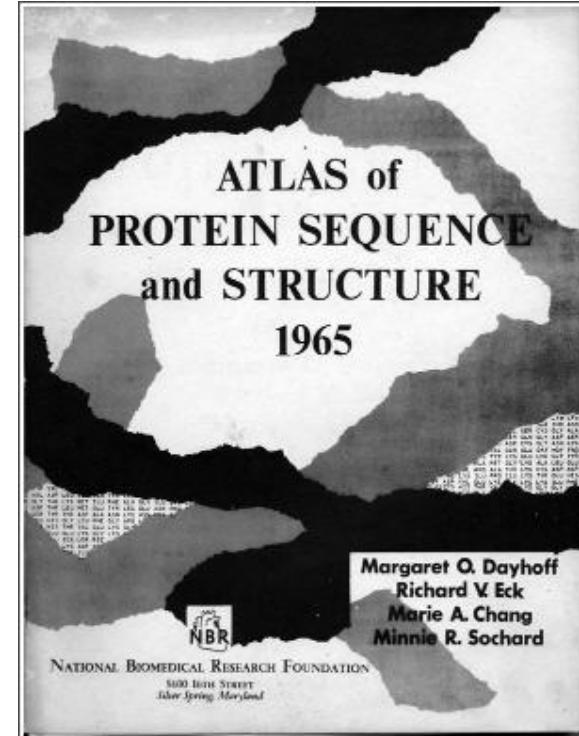
Bei **niedriger** gap opening penalty!

Substitutions-Matrizen für Proteine

- chemisch-funktionelle Ähnlichkeit der As bestimmt Wahrscheinlichkeit eines Austauschs während der Evolution.
Daher...
- ...sind die „Kosten“ bzw. die „Belohnung“ für bestimmte Austausche unterschiedlich hoch!
- Definition der Kosten erfolgt über **Matrizen**:
 - > **PAM-Matrizen** (Dayhoff 1978)
 - > **BLOSUM-Matrizen** (Henikoff & Henikoff 1992)
 - u. einige mehr

Margaret O. Dayhoff

1925-1983



PAM-Matrizen

PAM-Mat

		C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W
		C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W
Hydrophilic	Cysteine	12	0	2																	
	Alanine		0	1	3																
	Threonine	-2		1	3																
	Proline	-3	1	0	6																
	Glutamine	-2	1	1	1	2															
	Asparagine	-3	1	0	-1	1	5														
	Aspartic acid	-4	1	0	-1	0	0	2													
	Glutamic acid	-5	0	0	-1	0	1	2	4												
	Arginine	-5	0	0	-1	0	0	1	3	4											
	Lysine	-5	-1	-1	0	0	-1	1	2	2	4										
Basic	Arginine	-3	-1	-1	0	-1	-2	2	1	1	3	6									
	Lysine	-4	0	-1	0	-2	-3	0	-1	-1	1	2	6								
	Histidine	-5	0	0	-1	-1	-2	1	0	0	1	0	3	5							
	Basic																				
	Basic																				
Hydrophobic	Valine	-5	-2	-1	-2	-1	-3	-2	-3	-2	-1	-2	0	0	6						
	Isoleucine	-2	-1	0	-2	-1	-3	-2	-2	-2	-2	-2	-2	-2	5						
	Leucine	-6	-3	-2	-3	-2	-4	-3	-4	-3	-2	-2	-3	-3	4	2	6				
	Alanine	-2	-1	0	-1	0	-1	-2	-2	-2	-2	-2	-2	-2	2	4	2	4			
Aromatic	Phenylalanine	-4	-3	-3	-5	-4	-5	-4	-6	-5	-5	-2	-4	-5	0	1	2	-1	9		
	Tyrosine	0	-3	-3	-5	-3	-5	-2	-4	-4	-4	0	-4	-4	-2	-1	-1	-2	7	10	
	Tryptophan	-8	-2	-5	-6	-6	-7	-4	-7	-7	-5	-3	2	-3	-4	-5	-2	-6	0	0	17
	Aromatic		C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y

Fig. 5.7 The PAM 250 matrix. For each pair of amino acids (see Table 3.1, p. 41, for key to the one-letter codes for amino acids) the matrix gives the ratio of the frequency at which the pair is observed in pairwise comparisons of proteins to that are expected due to chance alone, expressed as a 'log odd'. Amino acids that regularly replace each other have a positive score, amino acids that rarely replace each other have negative scores. Note that replacements more often occur among chemically related amino acids (indicated on the left). From Dayhoff (1978: Fig. 84).

- „Percent Accepted Mutation“
(„accepted during evolution“)
 - 1 PAM entspricht 1% As-Austausch
 - positiver Wert = Aminosäuren, die sich häufig in Alignments gegenüberstehen und somit ‚funktionell konserviert‘ sind

z. B. W-W 17

C -C 12

P - P 6

aber W-V - 6

Bewertung eines As-Alignments

Sequenz 1

Sequenz 2

$$\begin{aligned}
 P:P &= +6 \\
 T:T &= +3 \\
 \dots \\
 I:M &= +2
 \end{aligned}$$

$$\begin{array}{rcl} \text{Score} & = & \\ 6+3+\dots+2 & = & \text{XX} \end{array}$$

Erstellung einer PAM -Matrix

1. Vergleiche problemlos zu alignierende, nahe verwandte Proteinsequenzen (>1572 Austausche in 71 Sequenzgruppen mit > 85% Sim.)
2. Kalkuliere die Austauschwahrscheinlichkeit jeder As relativ zu ihrer Häufigkeit in den Sequenzen und zur allgemeinen Mutabilität der Sequenzen
3. Berechne Score-Wert für As als „**log odds**“-Wert, d.h. als Logarithmus der Wahrscheinlichkeiten:

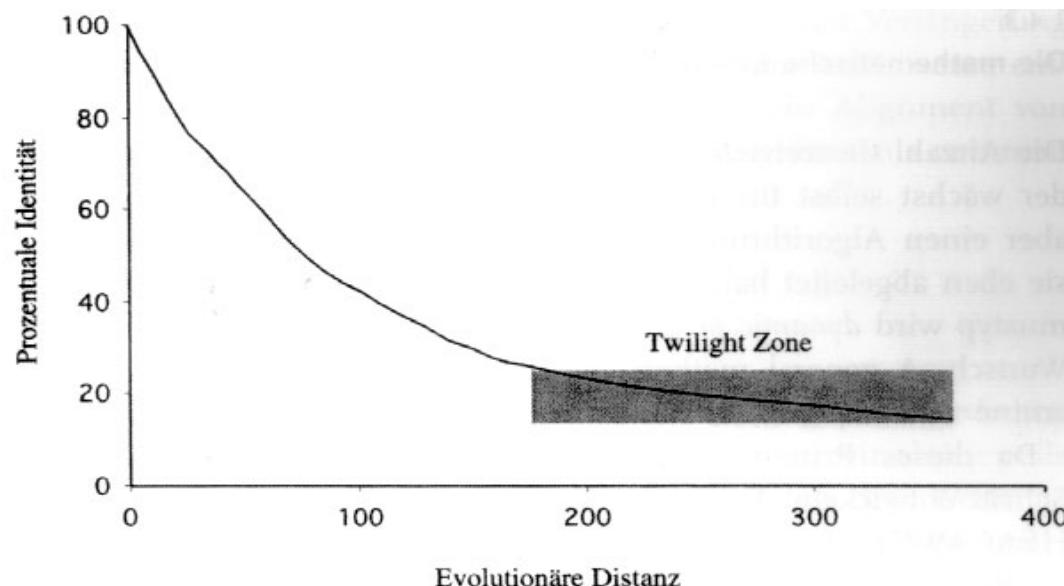
$$S(a,b) = \log \frac{p_{ab}}{q_a q_b}$$

joint probab.
Background frequency

4. „**Log odds**“-Scores können bei der Bewertung des Alignments anhand der Matrix einfach addiert werden

Erstellung einer PAM -Matrix

- Achtung: PAM 60/80/120/250 -Matrizen wurden durch Multiplikation der PAM 1 mit sich selbst **extrapoliert!**
- PAM 250 bedeutet, dass man durch multiple Austausche an derselben Position durchaus 250% As-Austausche erwarten kann. Dennoch haben diese entfernt verwandten Sequenzen noch bis 20% As-Ähnlichkeit:



PAM - Matrizen in der Kritik

1. zu kleiner Proteindatensatz bei Dayhoff:

die Original-PAMs basieren auf wenigen Proteinfamilien!
> besser: JTT-Matrizen nehmen 1991er-Datenbank

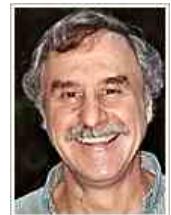
2. Extrapolationsverfahren:

die gebräuchlichen PAM100 oder PAM250 Matrizen sind bedingt durch die Extrapolation nur Vorhersagen

3. Weitere unzulässige Annahmen:

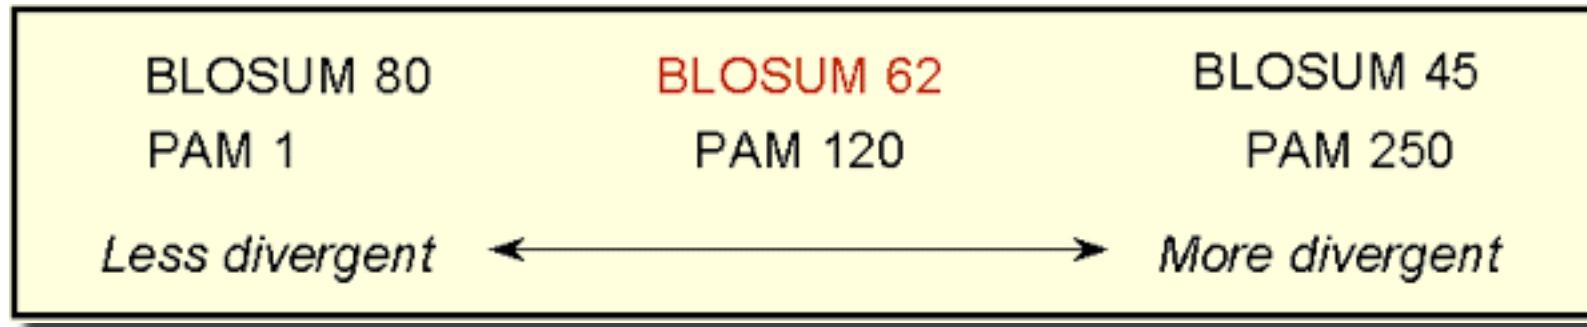
„Alle As-Positionen evolvieren unabhängig“; „Alle Positionen mutieren mit gleicher Wahrscheinlichkeit“

BLOSUM - Matrizen



- Blocks Substitution Matrix
- Scores errechnet nach beobachteten Austauschfrequenzen in „Blöcken“ aus lokalen Alignments auch z.T. entfernt sequenzverwandter, jedoch klar biochemisch verwandter Proteine (> 500 versch. Familien!)
- z. B. BLOSUM 62 : Scores abgeleitet von Sequenzen mit höchstens 62% As-Identität
- BLOSUM-Matrizen-Werte sind nicht extrapoliert u. nicht abhängig von einem evolutionären Modell.
- besonders geeignet für Alignment entfernt verwandter Proteinsequenzen

BLOSUM vs. PAM



PAM 60 für 60% ähnliche Proteine
80 50%
120 40%

Achtung: die meisten Matrizen in Vergleichsprogrammen haben assoziierte (und oft auch optimierte) Gap penalty-Scores! Vorsicht bei drastischen Änderungen der gap penalty-Werte relativ zu den Substitutions-Scores.

Wir haben also Kriterien (Substitutionsmatrizen, gap penalties), um Alignments zu bewerten.

**Aber wie werden Alignments
überhaupt erstellt?**



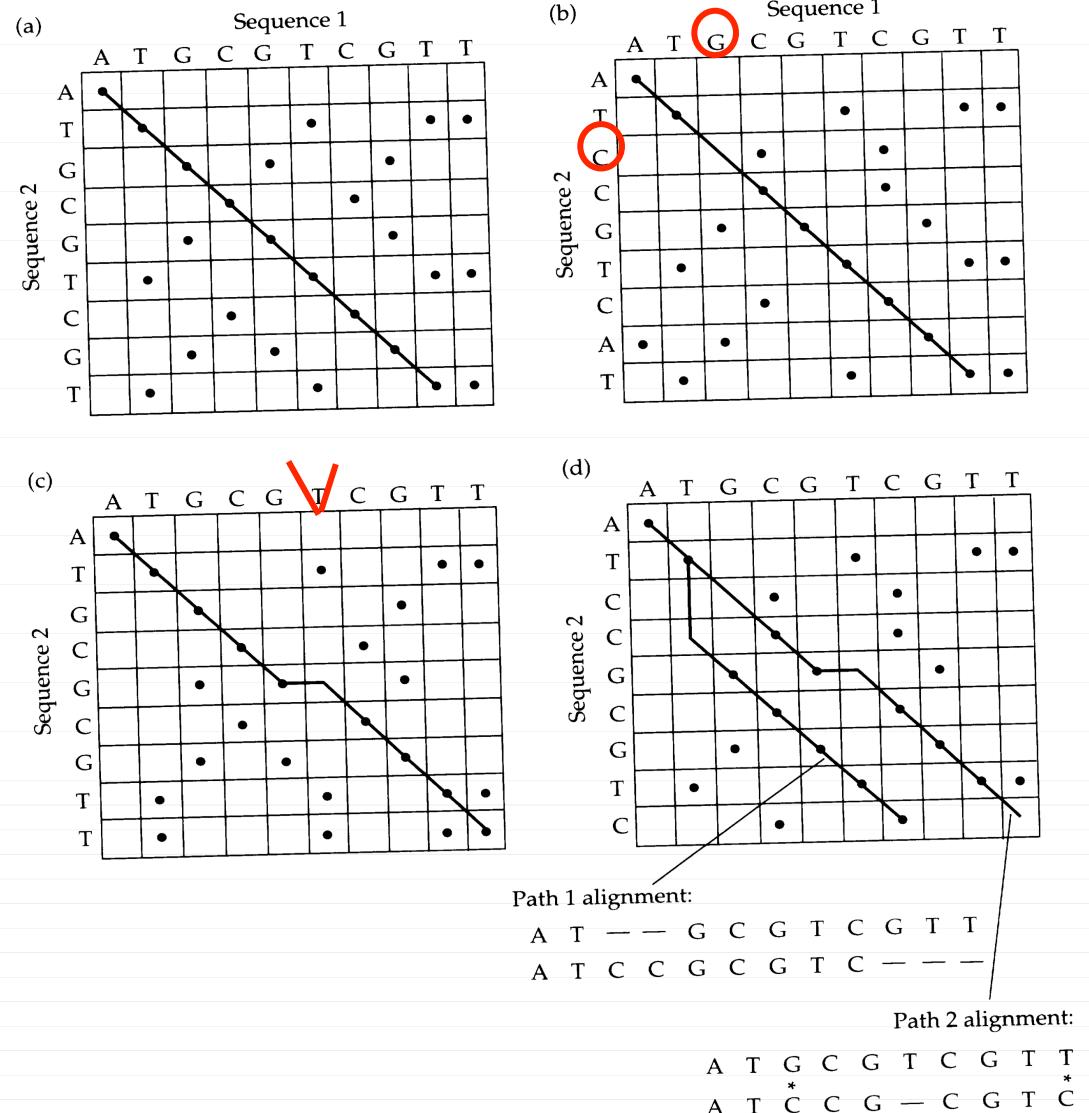
Bisher nur „Regeln“ für Alignment besprochen. Nun endlich...

Alignment-Methoden

- Dot-Matrix-Vergleich (Grafik)
- algorithmischer Vergleich
 - „dynamic programming“
 - „word/k-tuple“-Methoden

Vergleich von DNA per Dot-Plot

Gibbs, McIntyre 1970

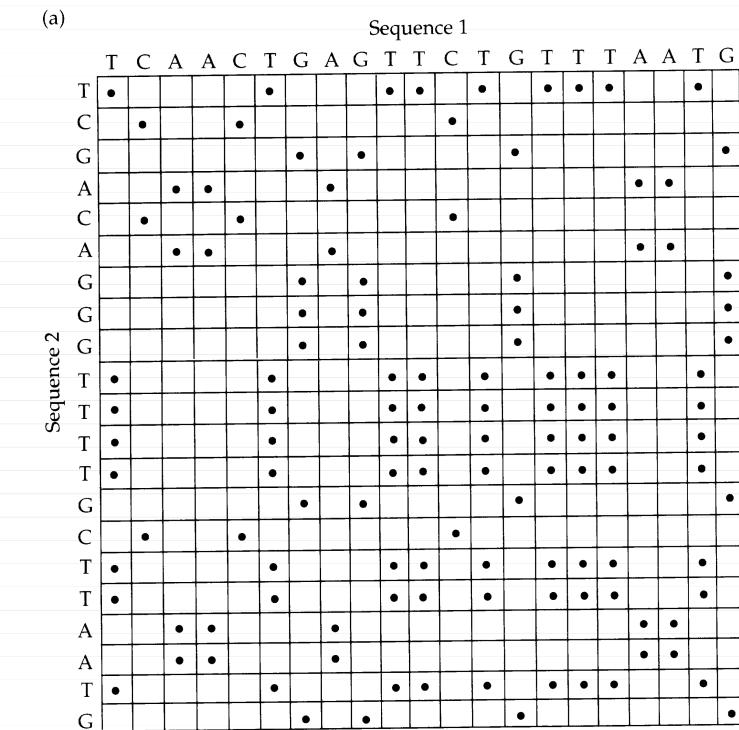


Dot plot Programm:
<http://bioweb.pasteur.fr/seqanal/interfaces/dottup.html>

Dot-Plot mit „sliding window“

Problem:

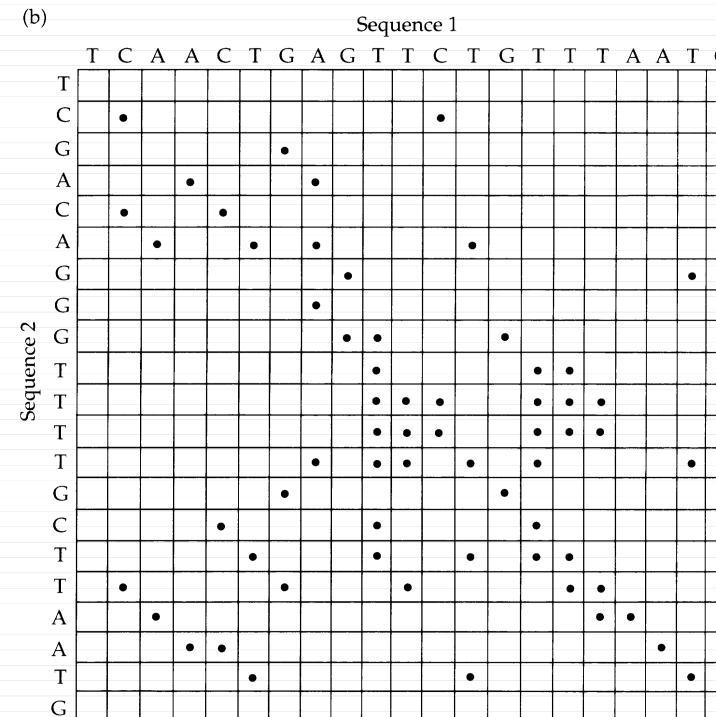
Diagonale ist versteckt



Lösung:

„sliding window“ als Filter

3 nt window size, 2/3 müssen passen

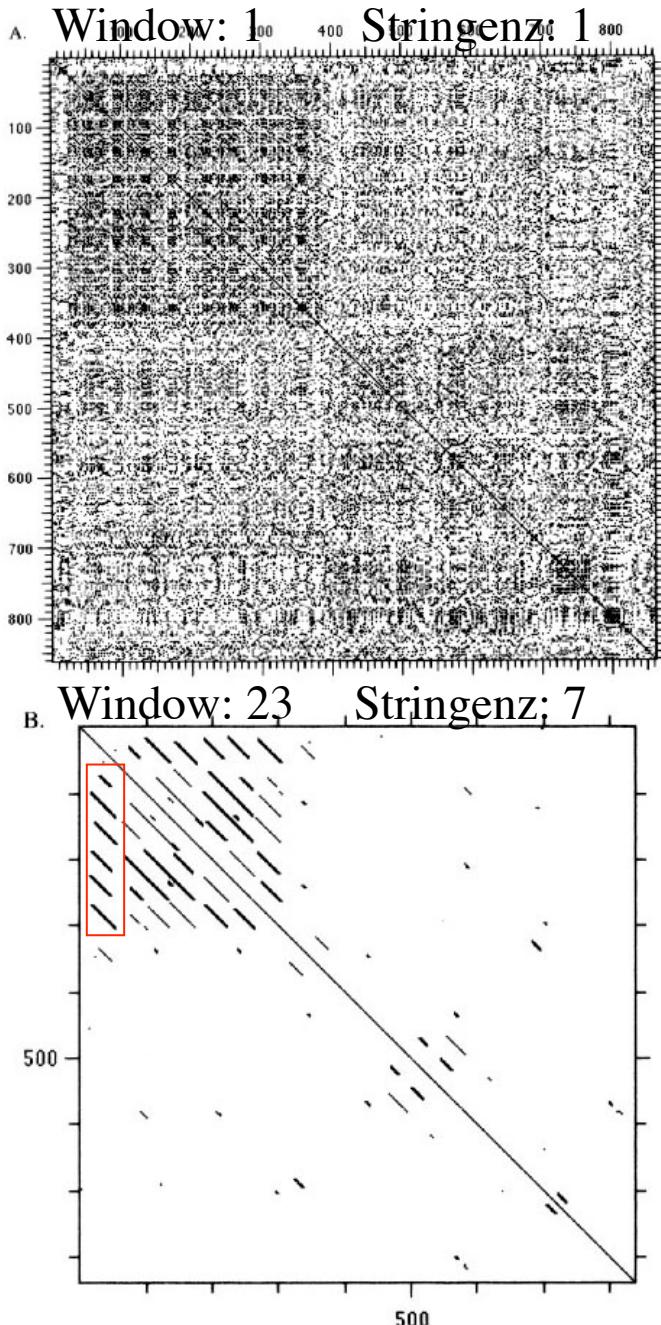


Dot-Plot mit ‚sliding window‘

Je kleiner das Fenster, desto größer die Auswirkung zufälliger Matches.

Große Fenster sind nicht gut geeignet für Entdeckung kurzer Matches.

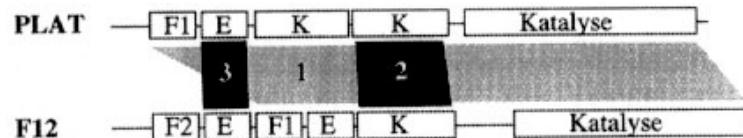
Stringenz bestimmt sichtbares Ergebnis in hohem Maße.



Dot-Plot zeigt Repetitionen

- LDL-Rezeptorgen mit sich selbst verglichen
- kurze Diagonalen abseits der Hauptdiagonalen **zeigen repetitive Sequenzregionen an!**
- bei Erhöhung der Stringenz auf 15/23 verschwinden die zusätzlichen Diagonalen:
 > die Repetitionen sind nur bis zu einem gewissen Grad ähnlich

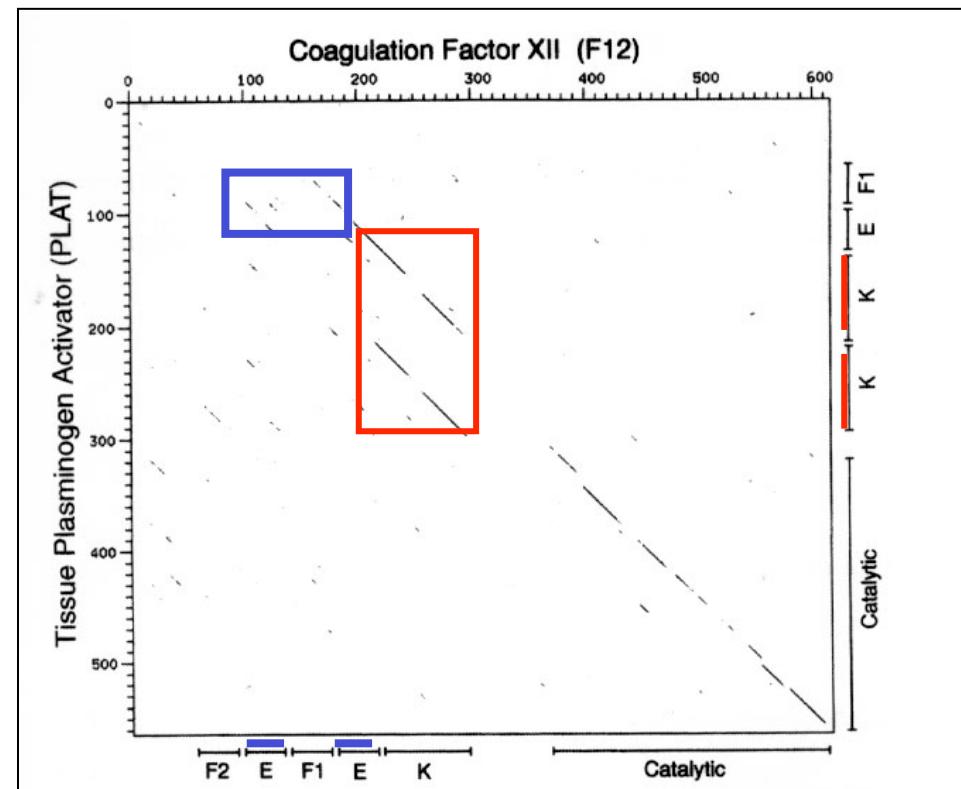
Dot-Plot zeigt Protein-Domänen



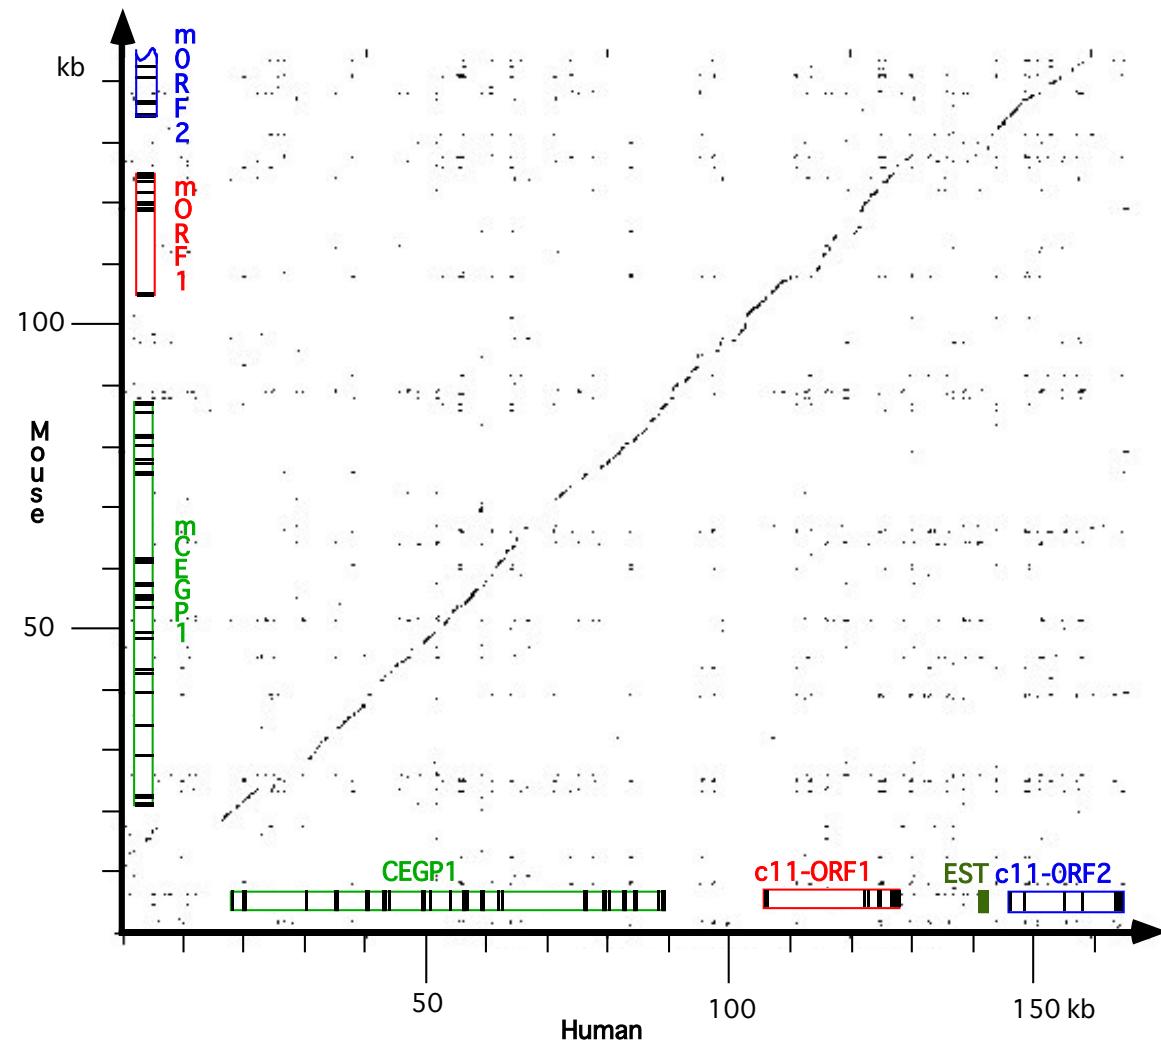
1.37 Die menschlichen Proteine PLAT (T-Plasminogen Activator) und F12 (Coagulationsfaktor XII) benutzen die gleichen 'Bausteine' in unterschiedlicher Anzahl und Reihenfolge. Neben dem optimalen lokalen Alignment (Bereich

F1-Domäne bis N-Terminus) müssen die *zusätzlichen* lokalen Alignments 2 (verdoppelte K-Domäne in PLAT) und 3 (verdoppelte E-Domäne in F12) erkannt werden, um die Domänenstruktur beider Proteine zu verstehen (s. a. Abb. 1.36).

Dot-Plots ermöglichen Entdeckung repetitiver Domänen in Proteinen



Dotplot zeigt syntäne Genombereiche



Mensch-Maus-
Genomvergleich
über ca. 150 kb

Warum ist ein „richtiges“ Alignment so problematisch?

- $2 \times 300 \text{ Bp} = 10^{88}$ mögliche Alignments!!!
- Computer-Algorithmen erforderlich, die ohne ausführliche Suche auskommen.

Alignment-Algorithmen: Globales vs. Lokales Alignment

- **globales Alignment:** z. B. Needleman-Wunsch
Nachteil: sehr aufwendig und langsam, aber komplettes alignment bis zu den Enden

ATTGTCCATGCAGCCTGAA
TATCGGGATGC--CTTATT

- **lokales Alignment:** z. B. Smith-Waterman
schnell, aber nur die lokal passenden Teile werden alignt, Lücken v. a. an den Enden sind nicht dargestellt

-----ATGC-----
-----ATGC-----

Needleman-Wunsch (N-W) 1970

- GLOBALES ALIGNMENT!
- Bei Erstellung des Alignments werden zunächst kleine Problem-Schritte gelöst. Dann wird aus den Teillösungen das Gesamtalignment rekonstruiert
- Algorithmus: „dynamic programming“

- Speicherbedarf: $\approx m \times n$

Bsp: Seq 1 (1kb) x Seq 2 (10kb) $> 10 \text{ Mb Speicher}$

Vorgehensweise von NW

(1)

	A	B	C	D
A	1	0	0	0
B	0	1	0	0
C	0	0	1	0
D	0	0	0	1

A B C D
A B C D

addiert auf dem
Weg durch
die Matrix

	A	B	C	D
A	4	0	0	0
B	0	3	0	0
C	0	0	2	0
D	0	0	0	1

Einfachster Fall:

Zwei identische Sequenzen
gegeneinander...

(2)

	A	C	D	E
A	1	0	0	0
B	0	0	0	0
C	0	1	0	0
D	0	0	1	0

A C D E
A B C D

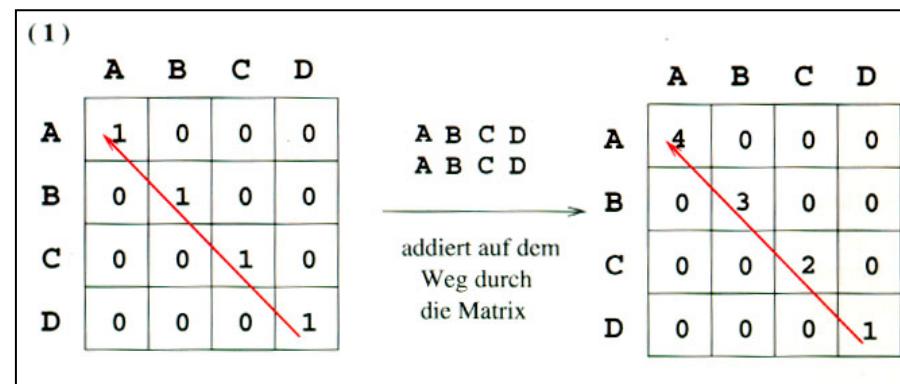
addiert auf dem
Weg durch
die Matrix

	A	C	D	E
A	3	0	0	0
B	0	2	0	0
C	0	2	0	0
D	0	0	1	0

Etwas schwieriger...

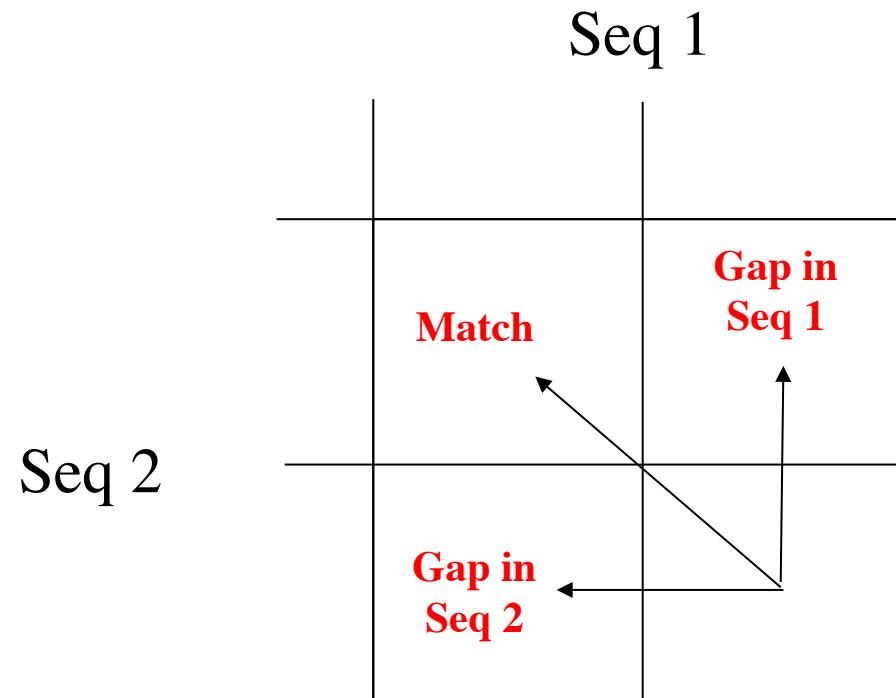
Vorgehensweise von NW

- wie beim Dotplot wird zunächst eine **zweidimensionale Matrix** mit den beiden zu vergleichenden Sequenzen erstellt
- in alle **Zellen der Matrix** wird der **Alignment-Score** für die jeweils verglichenen Sequenzpositionen hineingeschrieben. Die Berechnung des Score-Werts erfolgt natürlich anhand einer Substitutionsmatrix.
- das Alignment ergibt sich als Pfad durch die Matrix („**Traceback**“ vom End-Feld hin zum Start-Feld).
- Der Pfad mit der höchsten Endsumme repräsentiert das Alignment...



Needleman-Wunsch

- auch die Möglichkeit eines gaps muss bei Weg durch die Matrix berücksichtigt werden: > **Verlassen der Diagonalen**



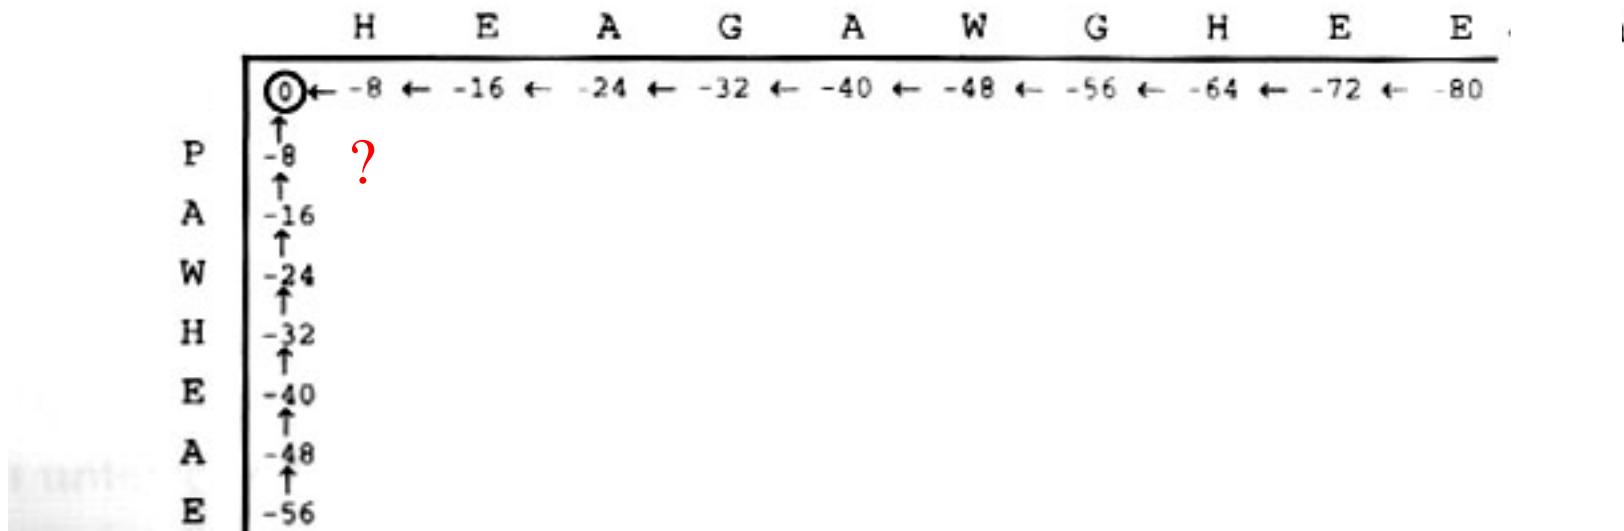
Needleman-Wunsch

Substitutions-
Matrix:

	H	E	A	G	W
P	-2	-1	-1	-2	-4
A	-2	-1	5	0	-3
W	-3	-3	-3	-3	15
H	10	0	-2	-2	-3
E	0	6	-1	-3	-3

Gap penalty -8

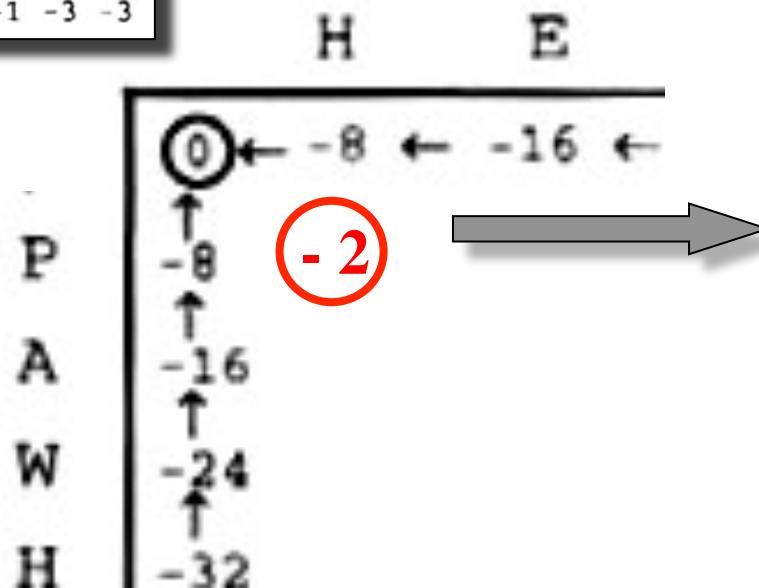
Sequenz X HEAGAWGHEE
Sequenz Y PAWHEAE



Needleman-Wunsch

$d = -8$

	H	E	A	G	W
P	-2	-1	-1	-2	-4
A	-2	-1	5	0	-3
W	-3	-3	-3	-3	15
H	10	0	-2	-2	-3
E	0	6	-1	-3	-3



3 Möglichkeiten!
Welche hat höchsten Score?

H
P

$$S = 0 + (-2) = -2$$

!

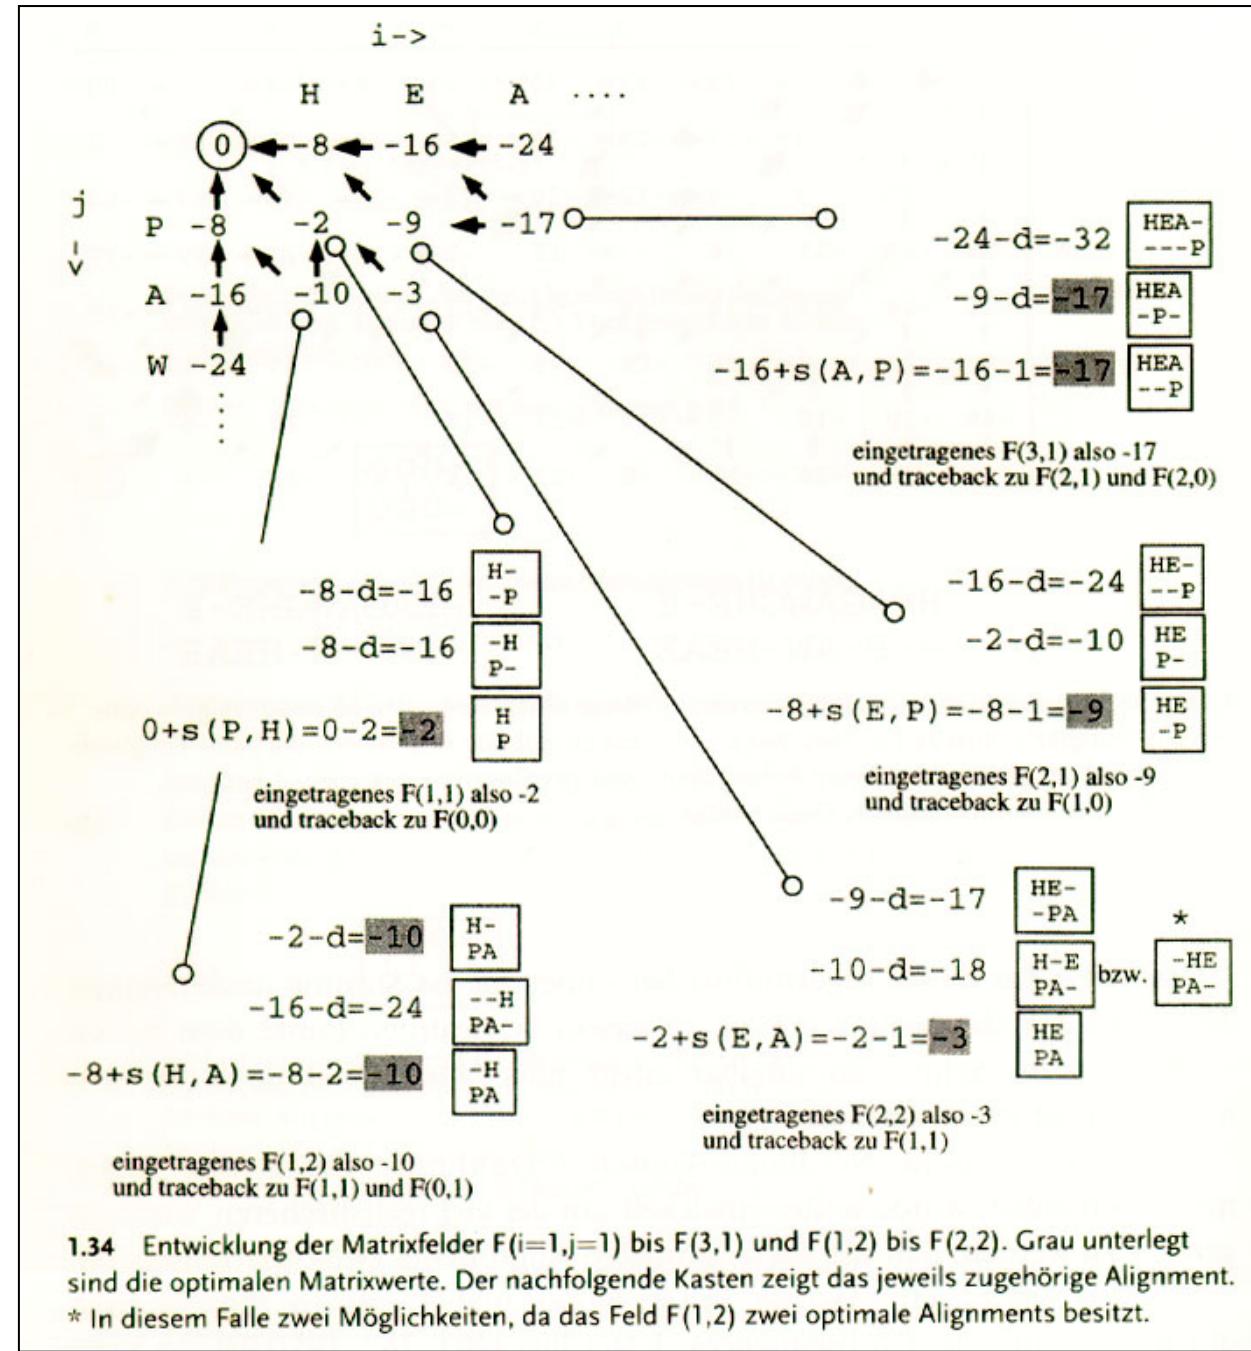
H
-
- P

$$S = -8 + d = -16$$

- H
P -

$$S = -8 + d = -16$$

Und so geht's weiter....



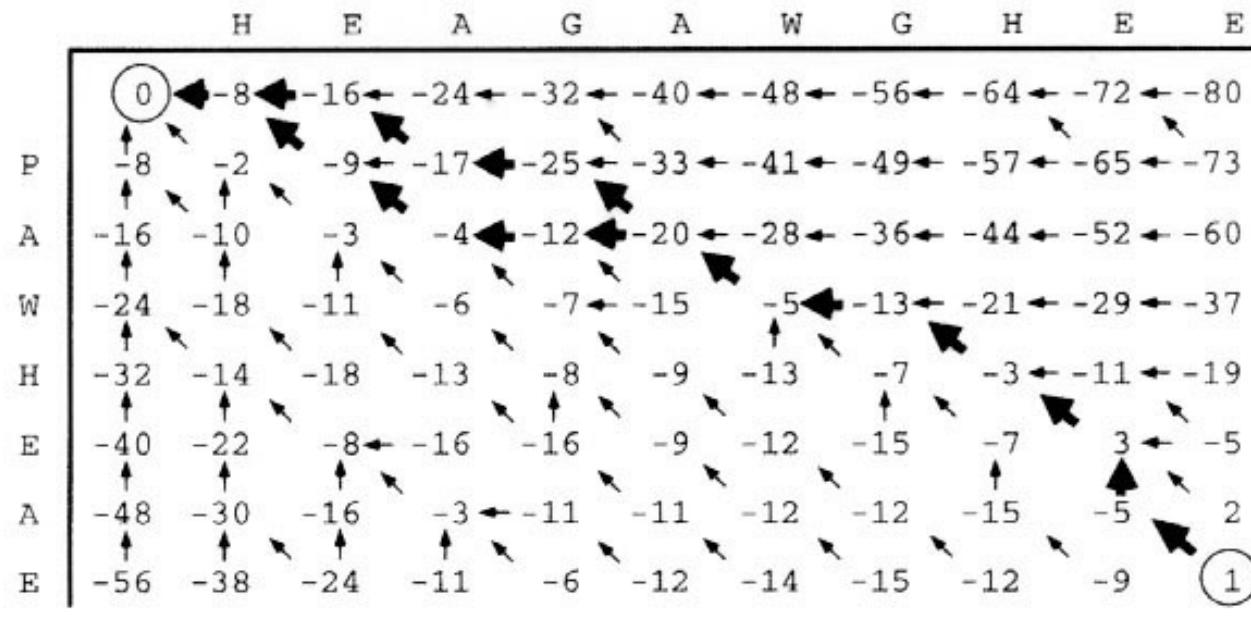
Aus:

Rauhut, Bioinformatik

1.34 Entwicklung der Matrixfelder $F(i=1,j=1)$ bis $F(3,1)$ und $F(1,2)$ bis $F(2,2)$. Grau unterlegt sind die optimalen Matrixwerte. Der nachfolgende Kasten zeigt das jeweils zugehörige Alignment.

* In diesem Falle zwei Möglichkeiten, da das Feld F(1,2) zwei optimale Alignments besitzt.

Needleman-Wunsch



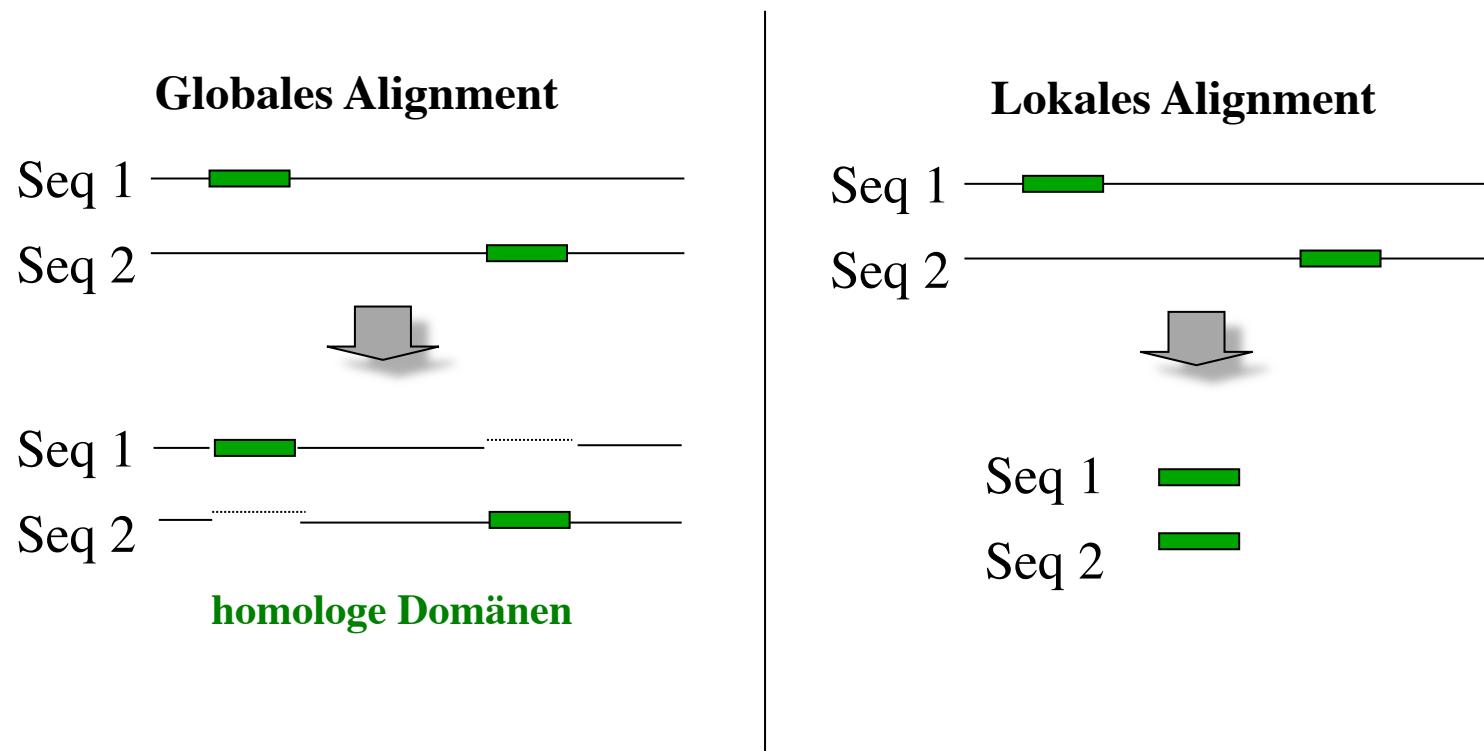
Trace-Back
der Pfeile
zeigt den
Weg des
optimalen
Alignments

- 1.33 Die fettgedruckten traceback-Pfeile der vervollständigten Matrix zeigen zwei Wege, um vom Endfeld mit dem score +1 zum Anfangsfeld mit dem score 0 zurückzufinden. Diese beiden Wege entsprechen den beiden gezeigten optimalen *globalen* Alignments, die beide ein gleichwertiges Gesamt-score von +1 besitzen.

Aber...

- das **globale** N-W Alignment funktioniert nur gut bei **relativ nahe verwandten** Sequenzen!!!
- das globale Alignment findet nicht...
 - ...homologe Domänen, wenn diese an unterschiedlichen Stellen in den Sequenzen liegen
 - ...kleinere konservierte Bereiche in ansonsten divergenten Sequenzen

Global vs. Lokal



Global vs. Lokal

1 AGGATTGGAATGCTCAGAAGCAGCTAAAGCGTGTATGCAGGATTGAAATTAAAGAGGGAGGTAGACCG.... 67
1 AGGATTGGAATGCTAGGCTTGATTGCCTACCTGTAGCCACATCAGAAGCACTAAAGCGTCAGCGAGACCG 70

14 TCAGAAGCAGCTAAAGCGT
42 TCAGAAGCA.CTAAAGCGT

1 AGGATTGGAATGCT
1 AGGATTGGAATGCT

39 AGGATTGGAAT
1 AGGATTGGAAT

62 AGACCG
66 AGACCG

Smith-Waterman (S -W) 1981

- finde den längsten gemeinsamen Bereich zweier Sequenzen mit der größten Ähnlichkeit
- liefert nur **EIN lokales Alignment** (das mit höchstem Score)!!!
- Berechnung ähnlich wie bei N-W, aber...
 -wenn alle 3 Alignmentmöglichkeiten an einer Position negative Scores haben, wird Score-Wert auf **0** gesetzt
 - > Pfade starten und enden innerhalb der Matrix

Smith-Waterman

	H	E	A	G	A	W	G	H	E	E
P	0	0	0	0	0	0	0	0	0	0
A	0	0	0	5	0	5	0	0	0	0
W	0	0	0	0	2	0	20	12	4	0
H	0	10	2	0	0	0	12	18	22	6
E	0	2	16	8	0	0	4	10	18	20
A	0	0	8	21	13	5	0	4	10	20
E	0	0	6	13	18	12	4	0	4	26

Somit ergibt sich das folgende optimale **lokale** Alignment

AWGHE mit einem score von 28
AW-HE

1.35 Die Berechnung der Matrix erfolgt genauso wie in Abb. 1.33 und 1.34. Sind aber die drei Möglichkeiten kleiner als Null, so wird der Matrixwert 0 eingetragen. Das *lokale* Alignment

beginnt nun an der Matrixposition mit dem höchsten score (hier +28) und endet wenn ein Nullfeld erreicht wird. Die traceback-Pfeile dieses Alignments sind fettgedruckt.

Zusammenfassung

- N-W maximiert matches und minimiert gap-Anzahl
> optimales Alignment mit höchstem Score
- N-W nur tauglich für relative ähnliche Sequenzen ohne Änderungen in ihrer Domänen-Architektur
- N-W- Programme:

GAP
Needle

in GCG-Programmpaket
<http://mobyle.pasteur.fr/cgi-bin/portal.py?#forms::needle>

Zusammenfassung

- S-W maximiert matches durch Einführung von gaps
> ein optimales lokales Alignment
- S-W sehr sensitiv für Domänensuche
- S-W liefert immer Ergebnis! Anwender muss beurteilen!
- S-W- Programme:

BESTFIT
WATER

in GCG-Programmpaket
<http://mobyle.pasteur.fr/cgi-bin/portal.py>



GCG- Programme

GAP (global)

A. GAP (Needleman-Wunsch algorithm)

Percent Similarity: 44.651 Percent Identity: 36.279

1 MSTKKKPL TQEQLEDARRL KAIYEKKKNEGLSQESVADKMGMGQSGVGA 50
1 MNT. QLMGER. I RARRKK. LK I RQAALGKMGVGVSNVA I SQ 37

51 LFNGINALNAYNAALLAKI LKVSVEEFSPS I ARE I YEMYEA VSMQPSLRS 100

38 WERSETEPNGENLLALSKA LQCSPDYL LKGDL SQTNVAYHS. . RHEPRG 84

101 EYEYPVFSHVQAGMFSP E RTFTKGDAERWVSTTKASD S AFW L E VEGNS 150

85 . . SYPL I SWV SAGQWMEAV EPYHKRA I ENWHDT TVDCSEDS FWLDVQGDS 132

151 MTAPTGSKP SFPDGML I LV DPEQAVEPGDFC I ARLGGD. EFTFKKL I RD S 199

133 MTAPAG. . LS I PEGM I I LV DPEVEPRNGKL VVAKLEG E N E A T F K K L V M D A 180

200 GQVFLQPLNPQYPM I PCNE SCSVVGKV I ASQWPEETFG 237

181 GRKFLKPLNPQYPM I E I NG NCK I I GVVVDAKLAN. . LP 216

B. BESTFIT (Smith-Waterman algorithm)

Percent Similarity: 58.871 Percent Identity: 48.387

104 YPVFSHVQAGMFSP E LRTFTKGDAERWVSTTKASD S AFW L E VEGNS MTA 153

86 YPL I SWV SAGQWMEAV EPYHKRA I ENWHDT TVDCSEDS FWLDVQGDS MTA 135

154 PTGSKP SFPDGML I LV DPEQAVEPGDFC I ARLGGD. EFTFKKL I RD S G Q V 202

136 PAG. . LS I PEGM I I LV DPEVEPRNGKL VVAKLEG E N E A T F K K L V M D A GRK 183

203 FLQPLNPQYPM I PCNE SCSVVGKV I AS 229

184 FLKPLNPQYPM I E I NG NCK I I GVVVDA 210

BESTFIT (lokal)



- Proteine enthalten oft wiederholte Domänen!

Die Programme LALIGN (fasta.bioch.virginia.edu/fasta_www/lalign.htm) und SIM (<http://www.expasy.ch/tools/sim.html>) können mehrere lokale Alignments in absteigender Qualität anzeigen!

- Die Programme FASTA und BLAST2 (eigentlich für Datenbank-Suchen gemacht; kein dyn. Program.-Algorithmus) können auch lokale Alignments machen.

<http://www.ncbi.nlm.nih.gov/blast/bl2seq/bl2.html>

<http://fasta.bioch.virginia.edu/>



GLOBAL

1 AGGATTGGAATGCTCAGAAGCAGCTAAAGCGTGTATGCAGGATTGGAATTAAAGAGGAGGTTAGACCG... 67

1 AGGATTGGAATGCTAGGCTTGAATTGCCTACCTGTAGCCACATCAGAAGCACTAAAGCGTCAGCGAGACCG 70

LOKAL

```
14 TCAGAAGCAGCTAAAGCGT  
        ||||||| |||||||  
42 TCAGAAGCA .CTAAAGCGT
```

```
14 TCAGAAGCAGCTAAAGCGT
          ||||||| |||||||||
42 TCAGAAGCA. CTAAAGCGT
```

Algorithm: Bestfit (Smith & Waterman)

identifiziert Region mit bester lokaler Ähnlichkeit

Algorithmus: SIM (Huang & Miller)

identifiziert **alle** Regionen mit lokaler Ähnlichkeit