

Quantifizierung evolutionärer Veränderungen

- Begriff der Homologie/Homoplasie
- Methoden des Sequenzvergleichs/Alignments
- Verfahren und Modelle zur Berechnung von Austauschraten in DNA und Proteinen

Thomas Hankeln, Institut für Molekulargenetik

SS 2010

JOHANNES
GUTENBERG
UNIVERSITÄT
MAINZ

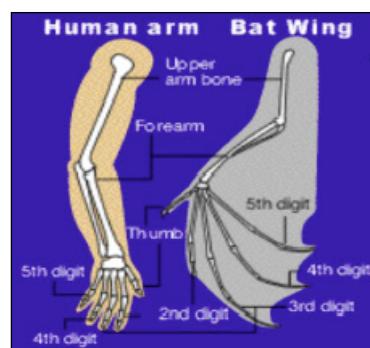
Der Begriff der Homologie



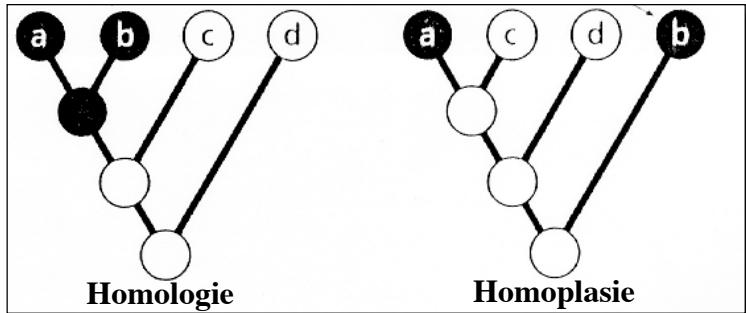
Richard Owen
1843

Homology: „the same organ under every variety of form and function (true correspondence)“

Analogy: „superficial or misleading similarity“



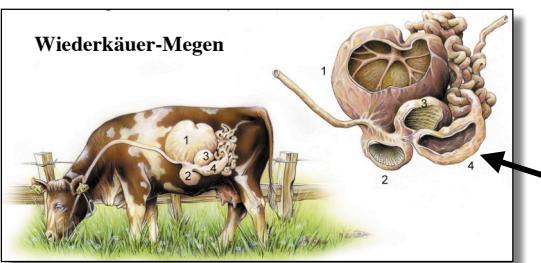
Homologie vs. Homoplasie/Konvergenz



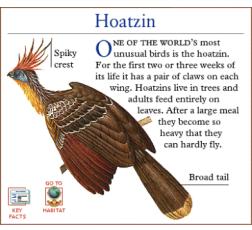
- Merkmal ‚Schwarz‘ von **gemeinsamem** Vorläufer geerbt

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

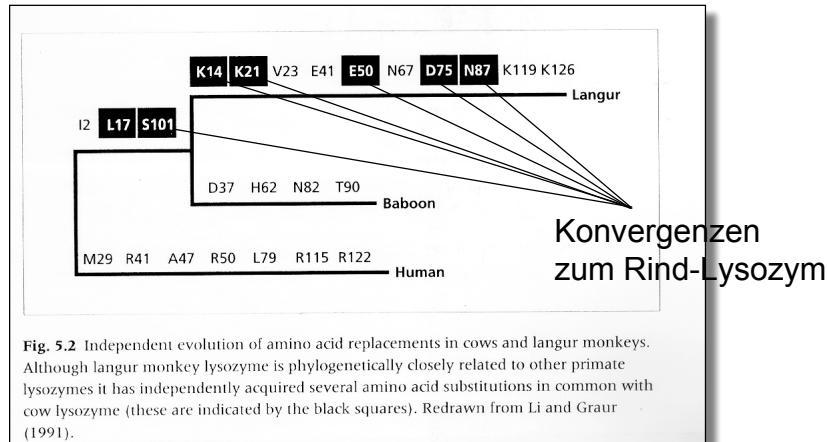
Beispiel: Konvergente Evolution in Proteinen



Spezielles Lysozym zum Verdau von Bakterien, die in bestimmten Magen-Abschnitten für den Aufschluss der pflanzlichen Nahrung sorgen



Beispiel: Konvergente Evolution in Proteinen



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!

Wie gehen wir also vor...?

1. Wir erstellen ein Sequenzalignment
 2. Wir schließen daraus auf ‚Homologie‘ (bei Gegenteil ist Vergleich sinnlos)
 3. Wir berechnen die Evolutionsereignisse, die ‚wirklich stattgefunden haben‘
 4. Wir können mit diesen Daten z.B. Stammbäume rekonstruieren oder Evolutionsereignisse datieren...

Vergleich von DNA- oder Proteinsequenzen durch „Alignment“

Nt-Substitution

As-Austausch/ replacement

Gap bzw. InDel

Query: 5 EPELIROQSWRAYRSPLRHGTWLFARLFALEPDLLPLFQY--NCRQFSSPEDCLSSPEFL 62
+ ELIR SW ++ ++ + HG +LF+RLF L+P+LL LF Y NC S +DCLSSPEFL
Sbjct: 8 DKELIRGSWDSLGNKVNPHGVILFSRLFELDPEELLNFHYTTNC---GSTDQCLSSPEFL 64

ähnliche As

identische As

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  MYKKILYPTDFSETAEIALKHKVAKFTLKAEEVILLHVIDEREIKKRDIFSLLLGVAGLN 63
         +YKKI+ PTD S+ + A KH      EV  ++V+D      S  +G+
Sbjct: 25  LYKKIVIPTDGSVDVSLEAAKHAINIAKEFDAEVYAIYVVD-----VSPFVGLPA-- 73

Query: 64  KSVEEFENELKNKLTEEAKNKMENIKKELEDEVGFVKVKKDIIIVVGIPHEEIVKIAEDEGVDI 123
         + E  +EL  I  EE +  ++ +KK  E+ G K+  ++ G+P  EIV+ AE + D+
Sbjct: 74  EGSWELISEL---LKEEGQEAALKVKVMAEEWGVKIHTEMLEGVPANEIVEFAEKKKADL 130

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

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

Wann DNA? Wann Protein?

GCT GAC TCT
Ala Asp Ser

Evolutionszeit  

GCG GAT AGC
Ala Asp Ser

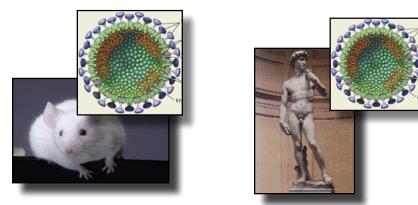
Während der Evolution wird die DNA durch 'stille' Mutationen stark verändert, während die Selektion die Veränderung auf Aminosäureebene weitgehend verhindert:

- Vergleich auf **DNA**-Ebene funktioniert nur zwischen **nahe verwandten Taxa/Genen**
- Vergleich auf **Aminosäureebene** kann noch **Ähnlichkeiten von entfernt verwandten Sequenzen** detektieren

Wann DNA? Wann Protein?



Eng verwandte SARS-Varianten
in der Population



Corona-Virus-Gruppen
aus verschiedenen Spezies

Alignment = Evolutionshypothese

Wir treffen durch die
Wahl des Alignments
eine **Annahme über den**
Ablauf der Evolution!!!!

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

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

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 ---- - - - - - -

Wie erstellt man ein möglichst „richtiges“ Alignment ?

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

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

...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!

Auswirkungen der gap penalty

(a) ALLLQPLLGAQGAPLEPVYPGDNATP-EQMAQ-YAAD-LRRYINMLTRPRYGRHKEDTLAF ----GPS----Q----P----TYPGDDA-PVED L I RFY--DNLQQYLNVVT----RHRY----	→ Penalty = 0
(b) ALLLQPLLGAQGAPLEPVYPGDNATPEQMAQYAADLRRYINMLTRPRYGRHKEDTLAF -----GPSQPTYPGDDA PVED L I RFYDNLQQYLNVVTRHRY-----	→ Penalty $w_k = 1 + 0.1k$
(c) ALLLQPLLGAQGAPLEPVYPGDNATPEQMAQYAADLRRYINMLTRPRYGRHKEDTLAF ::: ::: ::: ::: ::: ::: ::: ::: ::: ::: -----GPSQPTYPGDDA PVED L I RFYDNLQQYLNVVTRHRY-----	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.

→ Daraus werden „**Belohnungswerte**“ oder „**Kosten**“ errechnet, die uns helfen, ein bestmögliches Alignment zu erstellen

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

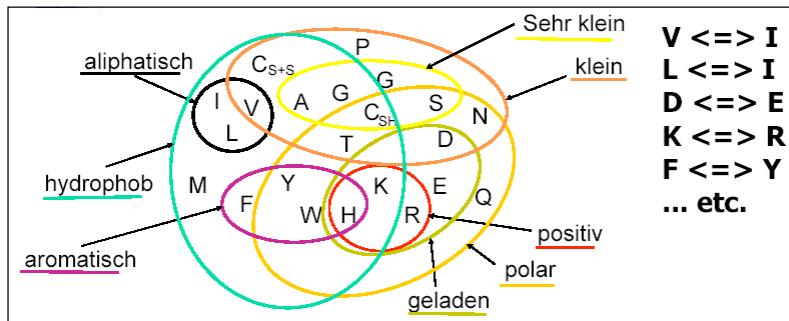
Gap-Parameter:

d = 1 (gap opening)
e = 0.1 (gap extension)

Bei niedriger gap opening penalty!

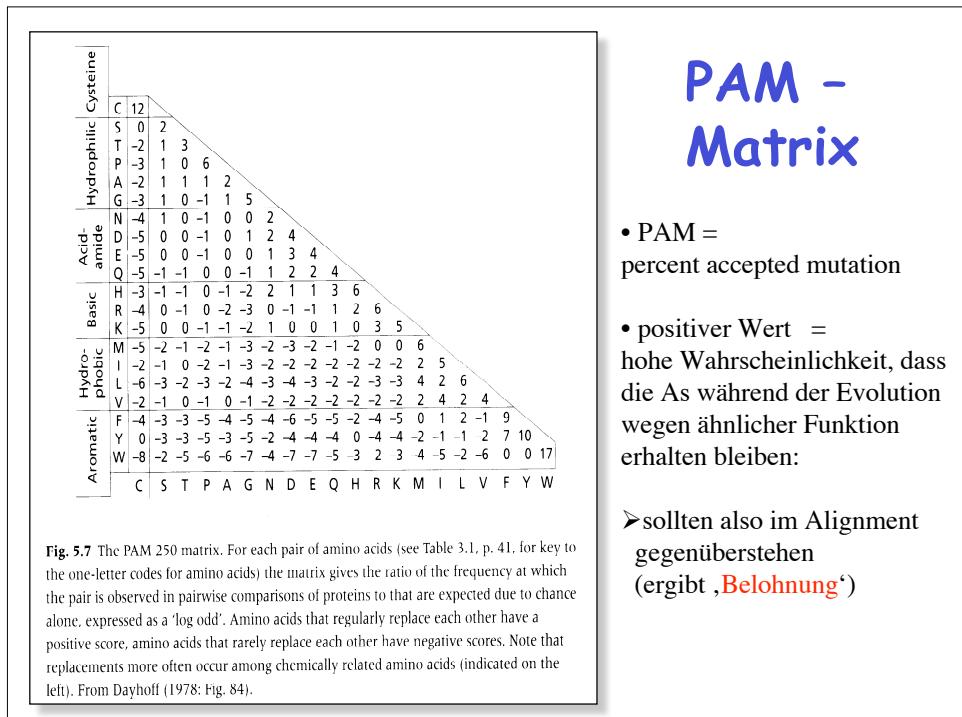
Substitutionsmatrizen bei Proteinen sind komplizierter

- bei **Proteinen** gibt es **20 As**
- chemisch-funktionelle Ähnlichkeit bestimmt Wahrscheinlichkeit eines Austauschs während der Evolution.



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 von Kosten bzw. Belohnung erfolgt über **Matrizen**:
 - > **PAM-Matrizen** (Dayhoff 1978)
 - > **BLOSUM-Matrizen** (Henikoff & Henikoff 1992)
 - u. einige mehr

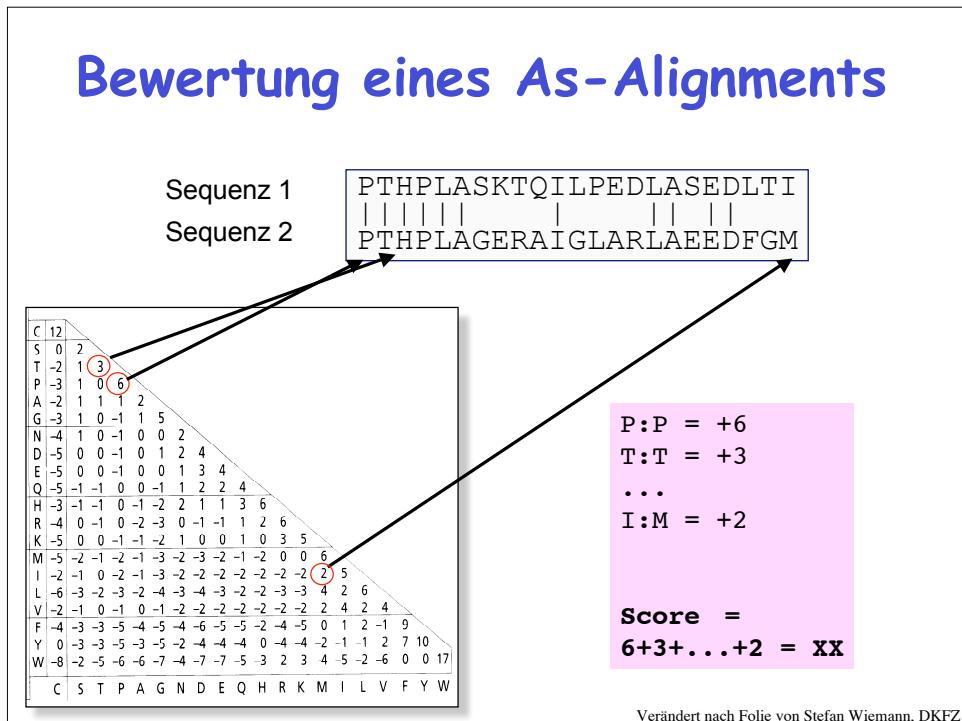


PAM - Matrix

- PAM = percent accepted mutation

- positiver Wert = hohe Wahrscheinlichkeit, dass die As während der Evolution wegen ähnlicher Funktion erhalten bleiben:

➤ sollten also im Alignment gegenüberstehen (ergibt „Belohnung“)



Und noch einmal...

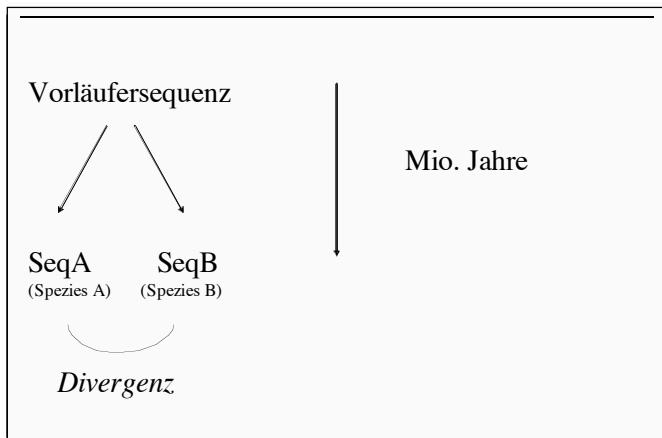
Das korrekte Alignment ist die Basisvoraussetzung für evolutionären Vergleich von Sequenzen!!!

Jedes unserer Alignments ist nur eine **evolutionäre Hypothese**. Es ist nur so „richtig“, wie die Annahmen richtig sind, die wir zugrundelegen!!!

Wie gehen wir vor...?

1. Wir erstellen ein Sequenzalignment
2. Wir schließen daraus auf ‚Homologie‘ (bei Gegenteil ist Vergleich sinnlos)
3. **Wir berechnen die Evolutionereignisse, die ‚wirklich stattgefunden haben‘**
4. Wir können mit diesen Daten z.B. Stammbäume rekonstruieren oder Evolutionereignisse datieren...

Veränderungen in Sequenzen während der Evolution



Ziel: Berechnen der Evolutionsereignisse, die 'wirklich statt gefunden haben'

Multiple Austausche

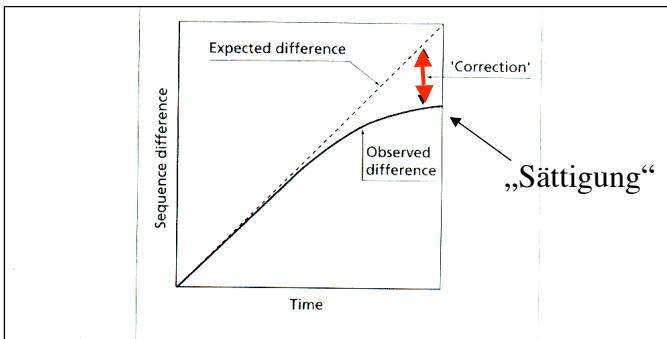
Problem:

Die sichtbaren Austausche zeigen nicht den wahren Umfang der Ereignisse während der Evolution!

Je mehr Evolutionszeit vergangen ist, desto höher ist die Chance, daß es an bestimmten Positionen **multiple Austausche** gegeben hat.

Figure 5. Two homologous DNA sequences which descended from an ancestral sequence and accumulated mutations since their divergence from each other. Note that although 12 mutations have accumulated, differences can be detected at only three nucleotide sites. Note further that "coincidental substitutions," "parallel substitutions," "convergent substitutions," and "back substitutions" all involve multiple substitutions at the same site, though maybe in different lineages.

Die beobachteten Divergenzwerte müssen hochkorrigiert werden...



...dies betrifft besonders Nt-Sequenzen!

Fig. 5.12 The need to correct observed sequence differences. The extent of observed differences between two sequences is not linear with time (as we would expect if the rate of molecular evolution is approximately constant) but curvilinear due to multiple hits. The goal of distance correction methods is to recover the amount of evolutionary change that the multiple hits have overprinted and to 'correct' the distances for unobserved hits. In effect, the methods seek to 'straighten out' the line representing observed differences.

Die beobachteten Divergenzwerte müssen hochkorrigiert werden...

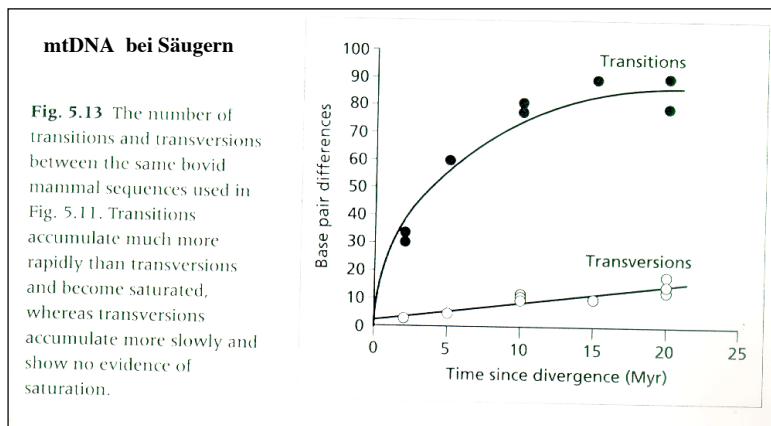
Q: Aber wie können wir die „wahren“, stattgefundenen Austausche extrapoliieren?

A: Wir müssen die richtigen Annahmen über den Verlauf der Evolution treffen (= wiederum [Modelle der Sequenzevolution](#) zugrundelegen).

z. B. ein bestimmtes Transitions/Transversions-Verhältnis, oder bestimmte bevorzugte Richtungen von Mutationen (zB GC > AT)

Die Art der Annahmen können wir zuvor aus unseren Sequenzvergleichsdaten ermitteln.

Unser Evolutionsmodell hier...



- Transitionen akkumulieren schnell > Sättigung
- Transversionen akkumulieren langsam und proportional zur Zeit

Modelle für die Evolution von Nukleotidsequenzen

- Jukes-Cantor (1969) one-parameter model (JC)
- Kimura two-parameter (K2P)
- Felsenstein 81
- Hasegawa, Kishino, Yano (HKY85)
- General time-reversible model (REV, GTR)

und viele andere...

<http://hev.lanl.gov/content/hev-db/findmodel/matrix/all.html>

<http://workshop.molecularevolution.org/resources/models/dnamodels.php>

Modelle für die Evolution von Nukleotidsequenzen

Alle diese Modelle treffen nur Annahmen für **Nukleotid-substitutionen!!**

Indel-Positionen werden nicht berücksichtigt. Sie werden sogar zumeist aus dem Sequenzvergleich entfernt!

- „complete deletion“ > sinnvoll wenn alignment in Bereichen mit Lücken unsicher ist
- „pairwise deletion“ > bei kleinen gaps, die statistisch über das Alignment verteilt sind

Modelle für die Evolution von Nukleotidsequenzen

- wie ist die Wahrscheinlichkeit, daß ein Nukleotid **i** zum Nukleotid **j** wird?

Parameter:
> Ausgangsfrequenz der einzelnen Basen
> Transitions/Transversions-Verhältnis
> individuelle Mutabilität jedes Nukleotids in jedes andere

Die Modelle treffen je nach Kompliziertheits-Grad für wenige oder viele dieser Parameter eine Annahme.

Das Jukes-Cantor (JC) „one parameter“-Modell

- alle 4 Basen haben dieselbe Frequenz
- alle Substitutionen sind gleich wahrscheinlich

$$K = - \frac{3}{4} \ln (1 - 4/3 p)$$

K = subst./ site

p = diverg. Posit./ Gesamtzahl der Nukleotide
(unkorrigierte „Hamming“-Distanz)

Achtung: bei $p > 3/4$ wird Formel ungültig!!!

Das Kimura „two-parameter“- Modell (K2P)

- alle 4 Basen haben dieselbe Frequenz
- Transitionen und Transversionen haben unterschiedliche Häufigkeiten

$$K = \frac{1}{2} \ln (1 / (1 - 2P - Q)) + \frac{1}{4} \ln (1 / (1 - 2Q))$$

P = divergente T_i pro Nt_{gesamt}
Q = div. T_v pro Nt_{gesamt}

JC vs. K2P

- Beispiel 1 : 2 Seq mit je 200 Bp
Divergenz 20 Ti, 4 Tv

$$P \text{ (unkorrigiert)} = 24 / 200 = 0,12$$
$$K \text{ (JC)} = 0,13$$
$$K \text{ (K2P)} = 0,13$$

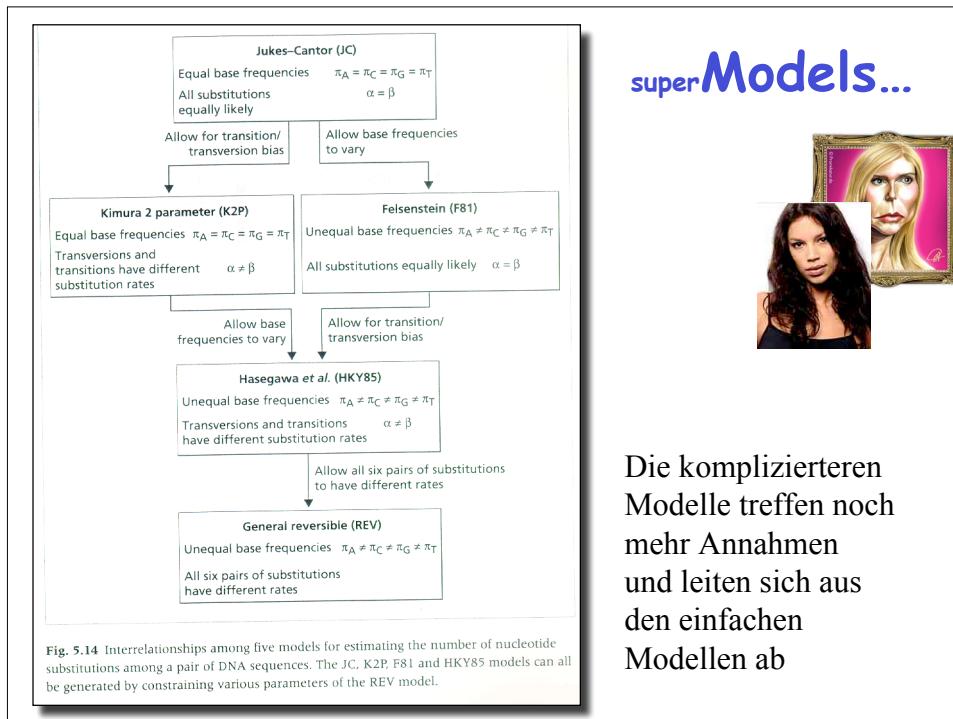
Wenn $p \ll 1$ (Divergenz sehr klein) ist, kann man das einfachste Modell (JC) nehmen oder gar auf Korrektur verzichten

JC vs. K2P

- Beispiel 2 : 2 Seq mit je 200 Bp
Divergenz 50 Ti, 16 Tv

$$P \text{ (unkorrigiert)} = 66 / 200 = 0,33$$
$$K \text{ (JC)} = 0,43$$
$$K \text{ (K2P)} = 0,48$$

Wenn Divergenz $> 0,15$ ist und ein unterschiedliches Ti/Tv-Verhältnis vorliegt, sollte man mindestens K2P-Korrektur durchführen



Die komplizierteren Modelle treffen noch mehr Annahmen und leiten sich aus den einfachen Modellen ab



Welches Modell soll man denn anwenden?

- je mehr Annahmen man trifft (komplizierte Modelle), desto exakter und realistischer sollte unsere Berechnung der Substitutionsrate ausfallen

ABER:

- Zusätzliche Parameter für komplizierte Modelle müssen wir aus unseren Daten abschätzen. Je mehr Annahmen man trifft (und Parameter einbezieht), desto größer wird der statistische Fehler (Varianz) unserer erhaltenen Werte!

Also: die niedrigste Zahl von Parametern (= das einfachste Modell“) nehmen, ohne jedoch die Exaktheit zu verlieren.

Welches Modell soll man denn anwenden?

MODELTEST: A tool to select the best-fit model of nucleotide substitution



© 1998-2006 David Posada
Current version is 3.7.

MODELTEST is a program for the selection of the model of nucleotide substitution that best fits the data. The program chooses among 56 models, and implements three different model selection frameworks: hierarchical likelihood ratio tests (hLRTs), Akaike information criterion (AIC), and Bayesian information criterion (BIC). The program also implements the assessment of model uncertainty and tools for model averaging and calculation of parameter importance, using the AIC or the BIC.

PROTTEST: Selection of best-fit models of protein evolution



© 2004-2006 Federico Abascal, Rafael Zardoya and David Posada
Current version is 1.3 (January 06).

Use of ProtTest's logo kindly allowed by [IconBAZAAR](#).

PROTTEST (ModelTest's relative) is a program for selecting the model of protein evolution that best fits a given set of sequences (alignment). This Java program is based on the [Phyml](#) program (for maximum likelihood calculations and optimization of parameters) and uses the [PAI library](#) as well. Models included are empirical substitution matrices (such as WAG, mtREV, Dayhoff, JTT, VT, Blosum62, CpREV, RRREV, MtMam and MtArt) that indicate relative rates of amino acid replacement, and specific improvements (+I:invariable sites, +G: rate heterogeneity among sites, +F: observed amino acid frequencies) to account for the evolutionary constraints imposed by conservation of protein structure and function. ProtTest uses the Akaike Information Criterion (AIC) and other statistics (AICc and BIC) to find which of the candidate models best fits the data at hand.

Austauschberechnungen in proteinkodierenden Genen

... erfordern spezielle Methoden, da synonome und nicht-synonome Kodonpositionen nach unterschiedlichen Gesetzmäßigkeiten evolvieren!

Austauschberechnungen in proteinkodierenden Sequenzen

- separat für syn und non-syn Austausche
- ATG & STOP-Kodons ausschließen, da invariabel
- bei mehreren Austauschen in 2 verglichenen Kodons müssen verschiedene Pfade der Evolution getrennt kalkuliert werden:

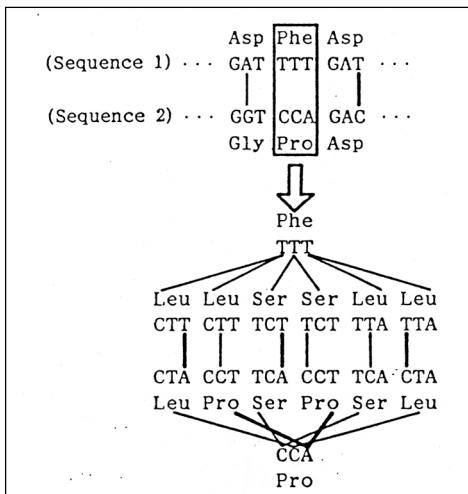
Bsp.1	GTC	>	GT _T	(1 syn)
	Val		Val	
Bsp. 2	AAT	>	ACG	?
	Asn		Thr	

Austauschberechnungen in proteinkodierenden Sequenzen

- bei mehreren Austauschen in 2 verglichenen Kodons müssen verschiedene Pfade der Evolution getrennt kalkuliert werden:

Bsp. 2	AAT	>	ACG	?
	Asn		Thr	
Pfad I	AAT	^{nonsyn} >	ACT	^{syn} > ACG
	Asn		Thr	Thr
Pfad II	AAT	^{nonsyn} >	AA _G	^{nonsyn} > ACG
	Asn		Lys	Thr

Austauschberechnungen in proteinkodierenden Sequenzen



- bei drei Austauschen in den verglichenen Kodons gibt es sogar 6 mögliche Pfade der Evolution

Austauschberechnungen in proteinkodierenden Sequenzen

- verschiedene Pfade sind unterschiedlich wahrscheinlich
- zwei Berechnungsmethoden zur Auswahl:
 1. „unweighted pathway methods“
 2. „weighted pathway methods“

Austauschberechnungen in proteinkodierenden Sequenzen: „N-G unweighted pathway method“

Nei & Gojobori MBE 3 (1986) pp.418

Hiv-web.lanl.gov/SNAP/WEBSNAP/SNAP.html

Schritt 1: Ermittlung der „potentiell syn“- und „potentiell nonsyn“-Positionen der einzelnen Kodons der Sequenzen A und B

	Phe	Leu	Leu
	T T T	C T A	T T A
pot. syn	0/3 0/3 1/3	1/3 0/3 3/3	1/3 0/3 1/3
Pot. nonsyn	3/3 3/3 2/3	2/3 3/3 0/3	2/3 3/3 2/3

Σ pot. syn sites_A

Σ pot. Nonsyn sites_A

Σ pot. syn sites_B

Σ pot nonsyn sites_B

Austauschberechnungen in proteinkodierenden Sequenzen: „N-G unweighted pathway method“

Schritt 2: Berechnung der durchschnittlichen Anzahl an „potentiell syn“- und „potentiell nonsyn“-Positionen der Sequenzen A und B

$$\bigcirclearrowleft \text{ Syn sites}_{A,B} = N_S$$

$$\bigcirclearrowleft \text{ Nonsyn sites}_{A,B} = N_A$$

Austauschberechnungen in proteinkodierenden Sequenzen: „N-G unweighted pathway method“

Schritt 3: Klassifizierung der Austausche zwischen A und B

<u>Seq A</u>	GTC Val	AAT Asn	Pfad 1: AAT>ACT>ACG 1 syn, 1 nonsyn Pfad 2: AAT>AAG>ACG 2 nonsyn
<u>Seq B</u>	GTT Val	ACG Thr	\otimes Syn = 0,5 \otimes Nonsyn = 1,5
	1 syn		

→ Insgesamt 1,5 syn. Substitutionen (= M_S)
1,5 nonsyn. Subst. (= M_A)

Austauschberechnungen in proteinkodierenden Sequenzen: „N-G unweighted pathway method“

Schritt 4: Berechnung zunächst der unkorrigierten, dann der für multiple Austausche korrigierten Distanzwerte

➤ Unkorrigiert: syn. Subst. / pot. syn. sites $P_S = M_S / N_S$

nonsyn Sub. / pot nonsyn sites $P_A = M_A / N_A$

➤ Korrigiert z. B. nach J-C:

$$K_S = -\frac{3}{4} \ln (1 - \frac{4}{3} P_S)$$

$$K_A = -\frac{3}{4} \ln (1 - \frac{4}{3} P_A)$$