

Bioinformatik

Phylogenetische Algorithmen




Ulf Leser / Silke Trißl
Wissensmanagement in der
Bioinformatik



BLAT Szenario

- Vergleich einer Maus-cDNA Q mit einer humanen cDNAs
- Hintergrundwissen über Menschen und Mäuse
 - Wenn es eine homologe Teilsequenz gibt, wird diese im **Schnitt zu m% identisch sein und eine durchschnittliche Länge von h haben**
 - Frameshifts (Insertions/Deletions) sehr unwahrscheinlich
- Frage
 - Wie lang müssen Seeds aus Q sein, damit wir mit **sehr hoher Wahrscheinlichkeit mindestens einen Treffer in einer homologen Region finden**, wenn es diese gibt?



BLAT – Statistik

- Ziel: **Minimales k und Anzahl von Hits abschätzen**
 - m: Erwartete Anzahl Matches in zwei Sequenzen
 - Z.B.: 99% für Maus-Mensch cDNAs, 90% für Proteine
 - h: Durchschnittliche Länge homologer Regionen
 - g: Größe der Datenbank (in Basen)
 - q: Länge der Querysequenz
 - a: Größe des Alphabets (DNA oder Protein)
- Berechnung
 - Wahrscheinlichkeit, dass **ein beliebiges k-mer** aus der Suchsequenz mit **seinem Gegenstück** in der homologen Datenbanksequenz perfekt matched
 - $p_1 = m^k$
 - Wahrscheinlichkeit, dass **mindestens ein nicht-überlappendes k-mer** aus T mit dem entsprechenden k-mer in Q perfekt matched (wenn Q, T homolog)
 - $p = 1 - (1 - p_1)^z = 1 - (1 - m^k)^z$

Trefferwahrscheinlichkeiten

Table 3. Sensitivity and Specificity of Single Perfect Nucleotide K-mer Matches as a Search Criterion

	7	8	9	10	11	12	13	14	
A.	81%	0.974	0.915	0.833	0.726	0.607	0.486	0.373	0.314
	83%	0.988	0.953	0.897	0.815	0.711	0.595	0.478	0.415
	85%	0.996	0.978	0.945	0.888	0.808	0.707	0.594	0.532
	87%	0.999	0.992	0.975	0.942	0.888	0.811	0.714	0.659
	89%	1.000	0.998	0.991	0.976	0.946	0.897	0.824	0.782
	91%	1.000	1.000	0.998	0.993	0.981	0.956	0.912	0.886
	93%	1.000	1.000	1.000	0.999	0.995	0.987	0.968	0.957
	95%	1.000	1.000	1.000	1.000	0.999	0.998	0.994	0.991
	97%	1.000	1.000	1.000	1.000	1.000	1.000	1.000	0.999

- $q=100$, m und k variabel (a und g hier nicht notwendig)
- Werte sind Wahrscheinlichkeit, dass **mindestens ein perfekter Match in der Region** vorkommt
- Ein Match reicht – Extensionsphase wird die **ganze Region** finden
- Beispiel
 - Bei erwarteter Sequenzähnlichkeit von $m=97\%$ findet man in einer homologen Region T von 100 Basen praktisch immer einen perfekten Match der Länge 13 für einen Substring der Länge q

Falsch-positive Treffer

- Aber: Wie viele k-mere **matchen zufällig?**
 - Abhängig von g, q und a
 - $F = (q-k+1) * (g/k) * (1/a)^k$
 - $(1/a)^k$: Alle Zeichen eines k-mers matchen per Zufall
 - (g/k) : Anzahl nicht-überlappender k-mere in DB
 - $(q-k+1)$: Anzahl (überlappender) k-mere in Query

B.	K	7	8	9	10	11	12	13	14
F		1.3e+07	2.9e+06	635783	143051	32512	7451	1719	399

$$a=4, \quad g=3 \cdot 10^9, \quad q=500$$

- Falsch-positive werden in **Extensionsphase** ausgesiebt
- **Trade-Off**
 - Hohe k-Werte: Wenig falsch-positive, aber eventuell fehlende echte Hits
 - Niedrige k-Werte: Viele falsch-positive, aber weniger falsch-negative

Weitere Möglichkeiten

- Suche mit mehreren (perfekten) Hits
 - Idee von BLAST-2
 - Wir sparen uns die Formeln
 - Drastische **Verringerung der erwarteten Anzahl falsch-positiver Hits**

Table 7. Sensitivity and Specificity of Multiple (2 and 3) Perfect Nucleotide K-mer Matches as a Search Criterion

	2,8	2,9	2,10	2,11	2,12	3,8	3,9	3,10	3,11	3,12
A.	81%	0.681	0.508	0.348	0.220	0.129	0.389	0.221	0.112	0.051
	83%	0.790	0.638	0.475	0.326	0.208	0.529	0.339	0.193	0.099
	85%	0.879	0.762	0.615	0.460	0.318	0.676	0.487	0.313	0.180
	87%	0.942	0.866	0.752	0.611	0.461	0.809	0.649	0.470	0.305
	89%	0.978	0.940	0.868	0.761	0.625	0.910	0.801	0.648	0.476
	91%	0.994	0.980	0.947	0.884	0.787	0.969	0.914	0.815	0.673
	93%	0.999	0.996	0.986	0.962	0.912	0.993	0.976	0.933	0.851
	95%	1.000	1.000	0.998	0.993	0.979	0.999	0.997	0.987	0.961
	97%	1.000	1.000	1.000	1.000	0.999	1.000	1.000	0.999	0.987
B.	N,K	2,8	2,9	2,10	2,11	2,12	3,8	3,9	3,10	3,11
	F	524	27	1.4	0.1	0.0	0.1	0.0	0.0	0.0

MSA – Beispiel

S_1 :	M---AIDE	---	NKQK	ALA	AALG	QIEK	Q	FGKGS	IMRLGEDR	-SMDVET	ISTG	SLSLDI
S_2 :	MSDN	-----	KKQQ	QALE	LALK	QIEK	Q	FGKGS	IMKLGDG	-ADHS	IEAIPSGSIALDI	
S_3 :	M---	AINTDTSGKQK	AL	TMVLN	QIERS	FGKG	AIMRLGDA	-TRMRVET	ISTGALT	LDL		
S_4 :	M-----	DRQK	ALE	AAVS	QIERA	FGKGS	IMKLGGKDQV	VETEVV	STRILGLDV			
S_5 :	M-----	DE	---	NKKRALAA	ALG	QIEK	Q	FGKG	AVMRMGDHE	-RQAIPAI	STGSLGLDI	
S_6 :	MD	-----	-----	-----	KIEK	FGKGS	IMKMGE	-VVEQVEV	IP	PTGSIALNA		
S_7 :	M-----	AL	-----	IE	-----	FGKG	-----	M--G	-----	L--		

- Uns interessieren „möglichst gute“ MSAs
 - Intuition
 - Möglichst wenig Spalten – wenig Leerzeichen
 - Möglichst homogene Spalten – hohe Übereinstimmung
 - Exakte Definition später
- MSAs erfassen das **Gemeinsame verschiedener Sequenzen**

MSA Überblick

- Weg über m-dimensionale Substitutionsmatrizen nicht gangbar
- Verschiedene alternative Vorschläge für Zielfunktionen existieren
 - Maximiere die Summe aller paarweisen Alignments
 - Maximiere die Summe der Alignments jeder Sequenz zu einer Consensussequenz (Center-Star)
 - Maximiere die Summe der Alignments folgend dem phylogenetischen Baum der Sequenzen


Definitionen


- Definition
 - Gegeben ein MSA M für Sequenzen S_1, \dots, S_k . Das durch M induziertes Alignment für zwei Sequenzen S_i und S_j ist das folgende:
 - Entferne aus M alle Zeilen außer i und j
 - Entferne alle Spalten, die in i und j ein Leerzeichen enthalten
 - Gegeben ein MSA M für Sequenzen S_1, \dots, S_k . Der Sum-Of-Pairs Score für M (SP-Score) ist die Summe aller Alignmentscores der durch M induzierten paarweisen Alignments
 - Das SP-Alignment Problem für Sequenzen S_1, \dots, S_k sucht das MSA M mit minimalem SP-Score
- Bemerkung
 - Vergleich aller Sequenzen mit allen anderen Sequenzen – aber entsprechend dem vorgegebenen MSA

Dynamische Programmierung in k Dimensionen

- $k = 2$
 - 2-dimensionale Matrix
- $k = 3$
 - 3-dimensionale Matrix


	0	1	2	3	4	5	6	7
0	0	1	2	3	4	5	6	7
1	v	1	1	2	3	4	5	6
2	i	2	2	2	2	3	4	5
3	n	3	3	3	3	3	4	5
4	t	4	4	4	4	3	4	5
5	n	5	5	5	5	4	4	5
6	e	6	6	6	6	5	4	5
7	r	7	7	6	7	6	5	4






Dyn Prog. für SP-MSA


- $d(i-1, j-1, k-1)$
- $d(i, j-1, k-1)$
- $d(i, j, k-1)$
- $d(i, j-1, k)$
- $d(i-1, j, k)$
- $d(i-1, j-1, k)$
- $d(i-1, j, k-1)$




1	G
2	A
3	C




1	-
2	A
3	C




1	-
2	-
3	C




1	-
2	A
3	-



1	G
2	-
3	-



1	G
2	A
3	-



1	G
2	-
3	C


Formal

- Wir nehmen ein einfaches Kostenmodell (I/D/R=1, M=0)
- Theorem
 - Gegeben Sequenzen S_1, S_2, S_3 .
 - Sei $d(i,j,k)$ der Score des SP-optimalen Alignments der Strings $S_1[1..i], S_2[1..j], S_3[1..k]$
 - Sei $c_{ij} = 0$, wenn $S_1(i) = S_2(j)$, sonst 1
 - Sei $c_{ik} = 0$, wenn $S_1(i) = S_3(k)$, sonst 1
 - Sei $c_{jk} = 0$, wenn $S_2(j) = S_3(k)$, sonst 1
 - Dann berechnet sich $d(i,j,k)$ als

$$d(i, j, k) = \min \left\{ \begin{array}{l} d(i-1, j-1, k-1) + c_{ij} + c_{ik} + c_{jk} \\ d(i-1, j-1, k) + c_{ij} + 2 \\ d(i-1, j, k-1) + c_{ik} + 2 \\ d(i, j-1, k-1) + c_{jk} + 2 \\ d(i-1, j, k) + 2 \\ d(i, j-1, k) + 2 \\ d(i, j, k-1) + 2 \end{array} \right.$$

MSA praktisch unlösbar?

- SP-Score für mehr als eine Handvoll Sequenzen nennenswerter Länge nicht berechenbar
- Außerdem: SP berechnet **nicht die Menge an notwendiger Evolution**



- Viele andere Zielfunktionen
 - Center-Star, MSA entlang des phylogenetischen Baums
- Viele Heuristiken (Branch&Bound, iterative, greedy, ...)

Progressives Alignment


- Grundproblem des SP-MSA
 - Ständige Betrachtung aller Sequenzen
 - Das sind zu viele Möglichkeiten = Dimensionen
- Grundidee der progressiven Verfahren
 - Berechne zunächst **MSA für viele kleine Teilmengen** von Sequenzen
 - Baue das **Gesamt-MSA aus den Teil-MSA**
- Das wirft Fragen auf
 - Wie wähle ich die Teilmengen?
 - Wie „aligniert“ man zwei MSA?
 - Wir können MSA (Profil) und Sequenz, aber zwei MSA?
 - In welcher Reihenfolge verschmilzt man die Teil-MSA?

CLUSTAL W: Grundaufbau


- Gegeben k Sequenzen
- Drei Schritte
 - Berechne alle paarweisen Alignmentscores
 - Konstruiere „Guide Tree“ durch hierarchisches Clustering
 - Berechne und verschmelze Teil-MSA gemäß dem Guide Tree
- Idee dahinter
 - Aligniere erst sehr ähnliche Sequenzen – **Signale werden verstärkt**
 - Werden z.B. zwei sehr verschiedene Cluster von Sequenzen betrachtet, berechnet CLUSTAL automatisch erst zwei (homogene) MSA und verschmilzt diese am Ende
 - Hohe Chance, dass **konservierte Blöcke** erhalten bleiben
 - **Außenseiter** kommen erst spät dazu und können die Blockstruktur nicht mehr stören
 - Orientierung an der „tatsächlichen“ Entstehungsgeschichte, dem **phylogenetischen Baum**

Konstruktion des Guide Trees



	A	B	C	D	E
A		17	59	59	77
B			37	61	53
C				13	41
D					21



	A	B	E	CD
A		17	77	59
B			53	49
E				31



	E	CD	AB
E			65
CD			54



Schritt 3: Progressive MSA Generierung

- Berechnung paarweiser Alignments in der Reihenfolge des Guide Trees
- Alignment eines MSA M_1 mit einem MSA M_2
 - Dynamische Programmierung mit linearem Gapscore
 - Wert eines Mismatches/Matches ist der Durchschnittsscore aller Paare mit einem Zeichen aus M_1 und dem anderen aus M_2
 - Gaps werden mit dem schlechtesten Score der verwendeten Substitutionsmatrix bestraft
 - Bei k Sequenzen sind das maximal $k/2 \cdot k/2 = O(k^2)$ Scores
- Beispiel

A	...P...
B	...G...
C	...P...
D	...A...
E	...A...
F	...Y...

- Score dieser Spalte

- $$- (2 \cdot s(P, A) + s(P, Y) + 2 \cdot s(G, A) + s(G, Y) + 2 \cdot s(P, A) + s(P, Y)) / 9$$

Inhalt dieser Vorlesung

- Stammbäume
- Ultrametriken
- Phylogenetische Algorithmen
 - Distanzbasiert: UPGMA
 - Neighbor Joining
 - Maximum Parsimony

Stammbäume versus Klassifikation

- Carl Linnaeus, ca. 1740: *Systema Naturae*
- Annahme: Arten verändern sich nicht
 - Prä-Darwin
- Einteilung der Lebewesen in
 - Kingdoms - classes – orders – families – genera – species
 - SKOFGA (Stamm, Klasse, Ordnung, Familie, Gattung, Art)
- **Innere Knoten** einer Klassifikation sind abstrakt
 - Es gab nie das Tier „Säugetier“ oder „Schädelknochen“
 - Vielleicht gab es ein Urwesen aller Säugetiere
 - Für eine Klassifikation ist das aber nicht notwendig



'Bridegroom portrait' of Linnaeus,
Carolus LINNAEUS, M.D.
METHODUS plantarum SEXUALIS
in SISTEMATE NATURE
descrip^{ta}



Linnaean sexual system
Illustration by Georg Dionysius Ehret of
Linnaeus' sexual system (1736)

Klassifikation

◀ [Eubacteria](#) ("True bacteria", mitochondria, and chloroplasts)

[Eukaryotes](#) (Protists, Plants, Fungi, Animals, etc.)

[Archaea](#) (Methanogens, Halophiles, Sulfolobus, and relatives)

- ?≡ [Viruses](#)

- Eukaryoten
- Tiere
- ... (diverse Zwischenstufen)
- Chordata (Schädelknochen)
- Vertebraten (Wirbeltier)
- ... (viele Zwischenstufen)
- Mammals (Säugetiere)
- Eutheria (Placenta)
- Primaten (Affen)
- Catarrhini
- Hominidae (Mensch, Schimpanse, Orang-Utan, Gorilla)
- Homo (erectus, sapiens ...)
- Homo Sapiens

Popular Groups on the Tree of Life

Eubacteria

Eukaryotes

Animals

- Echinoderms (sea urchins, starfish, sea cucumbers, etc)
- Vertebrates (fish etc.)**

 - Terrestrial Vertebrates**

 - Frogs
 - Salamanders
 - Turtles
 - Dinosaurs**

 - Modern Birds
 - Mammals

 - Teleost fish
 - Cnidaria (jellyfish, anemones, corals, etc.)
 - Annelida (segmented worms)
 - Cephalopoda (octopods, squids, etc.)

Arthropoda

Insects

- Dragonflies and Damselflies
- Lice
- True Bugs
- Beetles
- Wasps, Bees, and Ants
- Flies
- Butterflies and Moths
- Crickets, Katydids, and Grasshoppers

Arachnids

- Spiders
- Mites
- Scorpions



Fungi

Green Plants

- Ferns
- Flowering Plants


Stammbäume

- Charles Darwin: „The origin of species“ (1859)
 - Arten sind nicht unveränderlich, sondern unterliegen im Laufe der Zeit einem Wandel
 - „**Survival of the fittest**“
 - Damals war noch unklar, was sich eigentlich wandelt
- **Stammbäume** (Abstammungsbäume)
 - Ergeben sich aus der Annahme der Evolution
 - Jeder Knoten in einem Stammbaum hat einmal als Art existiert
 - Knoten im Baum (also Spezies) heißen **Taxa**
- Was definiert eine Spezies?




Moderne Stammbaumberechnung

- *Molecular phylogeny*
- Mendel + Darwin: Das Erbgut unterliegt dem Wandel
- Berechnung von Stammbäumen aus molekularen Daten
 - Zuckerkandl und Pauling, 1965
- Berechnung aufgrund von DNA oder Proteinsequenzen
- Annahme: **Evolution verläuft in kleinen Schritten**
- Wenn sich Sequenzen ähnlich sind, sind die Spezies evolutionär eng verwandt
 - Denn zufällige Ähnlichkeit ist zu unwahrscheinlich




Arten von Stammbäumen

- Individuelle Abstammung
 - Stammbäume, Ahnentafeln
 - Natürlich **kein Baum**: Zwei Eltern
 - Rekombination
- Speziesstammbäume
 - Ein Baum, wenn **Spezies nicht verschmelzen** können
 - Sprachen verschmelzen
- Gene Trees
 - Geschichte eines Sequenzabschnitts
 - Nicht leicht zu definieren
 - Baumförmig, wenn Gene nicht verschmelzen
 - Aber: 2 Allele jedes Gens vorhanden (Besser: **Haplotype Tree**)




Artenbildung

- Arten entstehen durch Veränderungen aus **einer** anderen Art




Daten

- Man kennt nur die DNA existierender Arten
 - (Einschränkung: Sequenzen von Neantertalern, ...)
- Zwei mögliche Ziele
 - Rekonstruktion des wahrscheinlichsten **Stammbaums** der Arten
 - Rekonstruktion der wahrscheinlichsten **Ur-DNA** und aller Zwischenstufen
- Den **tatsächlichen Stammbaum** kann man nicht berechnen
 - Man kennt die ausgestorbenen Arten nicht
 - Man kann ausgestorbene Mutationen nicht erkennen
 - Man kann Doppelmutationen nicht erkennen




Bäume

- Knoten = Arten
- Blätter = Lebende Arten
- Kanten
 - Länge kann (aber muss nicht) mit zeitlicher Entfernung korrelieren
 - **Scaled trees**
- Jeder Knoten hat exakt einen Vater
- Eine Wurzel
 - Nicht immer (gleich)
- Binäre Bäume
 - Unproblematisch (gleich)
 - **Reihenfolge der Kinder ist egal**
- Viele Visualisierungsvarianten







Bäume ohne Wurzeln

- Kanten symbolisieren Veränderungen
- Wir können nur Blätter vergleichen
- Damit ist idR **keine Richtung** der Entwicklung berechenbar



Wie schwierig wird das?

Wie viele binäre, ungeordnete Bäume für n Spezies gibt es?



Ergebnis

- Sei $t(n)$ die Zahl binärer Bäume mit n Blättern

$$t(n) = t(2) * t(3) * t(4) * \dots * t(n-1) =$$

$$= 1 * 3 * 5 * \dots * (2(n-1) - 1) =$$

$$= \frac{(2n-3)!}{2 * 4 * 6 * \dots * (2n-4)} =$$

$$= \frac{(2n-3)!}{2\left(\frac{2}{2}\right) * 2\left(\frac{4}{2}\right) * 2\left(\frac{6}{2}\right) * \dots * 2\left(\frac{2n-4}{2}\right)} =$$

$$= \frac{(2n-3)!}{2 * (1) * 2 * (2) * 2 * (3) * \dots * 2(n-2)} =$$


$$= \frac{(2n-3)!}{2^{n-2} * (n-2)!}$$

1	1
2	1
3	3
4	15
5	105
6	945
7	10.395
8	135.135
9	2.027.025
10	34.459.425
11	654.729.075
12	13.749.310.575
13	316.234.143.225
14	7.905.853.580.625
15	213.458.046.676.875
16	6.190.283.353.629.370
17	191.898.783.962.511.000
18	6.332.659.870.762.850.000
19	221.643.095.476.700.000.000
20	8.200.794.532.637.890.000.000

Inhalt dieser Vorlesung


- Distanzbasierte Phylogenie
- Ultrametriken und UPGMA
- Additive Bäume und Neighbor Joining

Voraussetzungen



- An innere Knoten eines Stammbaum kann man den Speziationzeitpunkt schreiben („branch points“)
- Wenn die Molecular Clock Theory gilt
 - Ist die Menge an Veränderungen auf einer Kante proportional zu der verstrichenen Zeit
 - Damit proportional zur Länge der Kante
 - Damit ist der Editabstand zweier Knoten (=Evolution dazwischen) proportional zur Summe der Editabstände beider Knoten zum kleinsten gemeinsamen Vater
 - Damit ist der Editabstand zweier Knoten proportional zur Summe der Kantenlängen zum jüngsten gemeinsamen Vorfahren

Ultrametriken



- Wenn man den Baum und die Zeitpunkte weiß, dann gilt
 - Alle Zahlen auf einem Pfad von der Wurzel zu einem beliebigen Blatt nehmen strikt ab
 - Der **Zeitpunkt der Aufspaltung** ist ein **Abstandsmaß** für zwei Arten
 - Für Blätter X, Y sei $d(X,Y)$ das Label des kleinsten gemeinsamen Vorfahren
 - Im Beispiel: $d(A,B)=80$, $d(B,C)=100$, $d(A,D)=80$
 - Das ist eine Metrik
 - $d(X,X)=0$, $d(X,Y)>0$, $d(X,Y)=d(Y,X)$, und $d(X,Y)\leq d(X,Z)+d(Z,Y)$
 - Es ist sogar eine **Ultrametrik** (gleich)

Alles ganz einfach?

- Wir zeigen gleich
 - Schreibt man diese Abstände in eine Ähnlichkeitsmatrix, hat diese bestimmte Eigenschaften
 - Jede Matrix mit diesen Eigenschaften entspricht genau einem Baum und umgekehrt
 - Den Baum kann man aus der Matrix effizient berechnen
- Also ist das Phylogenie-Problem überhaupt kein Problem?
- Doch
 - Molecular Clock Theory stimmt nicht
 - Editabstand korreliert nicht mit der vergangenen Zeit
 - Selektionsdruck
 - Damit kennen wir die Speziationszeitpunkte nicht
 - Man kann das alles nur approximieren
- Wenn die Molecular Clock Theory aber gelten würde ...

Ultrametrische Bäume

- **Definition**

*Sei T ein Baum und D eine symmetrische Matrix mit n Zeilen und n Spalten. T heißt **ultrametrischer Baum für D** wenn gilt:*


- *T hat n Blätter, beschriftet mit den Zeilen von D*
- *Jeder innere Knoten von T hat zwei Kinder und ist mit einem Wert aus D beschriftet*
- *Auf jedem Pfad von der Wurzel zu einem Blatt in T sind die Zahlen strikt abnehmend*
- *Für alle Blätter i, j mit $i \neq j$ gilt: der kleinste gemeinsame Vorfahr von i und j ist mit $D(i, j)$ beschriftet*

- **Bemerkung**

- *Jeder Stammbaum ist ultrametrisch für die Abstandsmatrix mit den Aufsplitzzeitpunkten als Abstandsmaß*


Beispiel

	A	B	C	D	E
A		8	8	5	3
B			3	8	8
C				8	8
D					5
E					



Das geht nicht immer

	A	B	C
A		8	5
B			3
C			



Überlegungen

- Das kann auch nicht immer gehen
 - Matrix hat $(n^2-n)/2$ relevante Zellen
 - Baum hat nur $n-1$ innere Knoten
 - Eine Matrix, zu der man einen ultrametrischen Baum konstruieren kann, muss also Duplikate enthalten
- *Definition*

Eine symmetrische Matrix D mit n Spalten und Zeilen ist ultrametrisch, wenn für beliebige Zeilen i, j, k gilt, dass das Maximum von $D(i,j)$, $D(j,k)$ und $D(i,k)$ genau zweimal vorkommt
- Bemerkung
 - Also entweder
 - $D(i,j)=D(j,k)$ und $D(i,j)>D(i,k)$
 - $D(i,j)=D(i,k)$ und $D(i,j)>D(j,k)$
 - $D(j,k)=D(i,k)$ und $D(j,k)>D(i,j)$

Von der Matrix zum Baum und zurück

- Theorem

Eine symmetrische Matrix D hat einen ultrametrischen Baum gdw. D selber ultrametrisch ist.

Sei D eine ultrametrische Matrix. Dann gibt es genau einen ultrametrischen Baum T für D .

- Beweis

- ...

Distanzbasierte Algorithmen

- Konstruktion des ultrametrischen Baumes basiert rein auf Distanzmassen
 - Einen ultrametrischen Baum gibt es nicht für alle Matrizen
 - Es gibt weniger empfindliche Verfahren (gleich)
- Die Geschichte einzelner „Sites“ wird nicht berücksichtigt
- Solche Algorithmen zur Berechnung von Stammbäumen nennt man **distanzbasiert**
- Alternative: **Merkmalsbasierte Verfahren**
 - Beachten jedes einzelne Merkmal (Sequenzposition)
 - Z.B. Perfect Phylogeny; Maximum Parsimony
 - Später

UPGMA - Hierarchisches Clustering


- UPGMA
 - „Unweighted pair group method with arithmetic mean“
 - Anderer Name: **Hierarchisches Clustering**
- Sehr einfaches und allgemeines Verfahren, kann bei allen möglichen Problemen angewandt werden
- Wenn eine Matrix ultrametrisch ist, dann findet UPGMA den dazugehörigen ultrametrischen Baum
 - UPGMA nimmt die Molecular Clock an – alle Pfade von einem Blatt zur Wurzel haben am Ende die selbe Länge
- Achtung: UPGMA konstruiert immer einen Baum
 - Auch wenn die Matrix nicht ultrametrisch ist

UPGMA Verfahren


- Gegeben: Distanzmatrix D
- Erzeuge ein „Baumgerüst“ mit n Blättern
- Wähle den kleinsten $D(i,j)$ Wert der Matrix und verbinde die Knoten i und j durch einen neuen Knoten (ij) mit Beschriftung $D(i,j)$ und Kanten zu i und zu j
 - Anfangs sind i und j Blätter, später können es auch innere Knoten sein
- Lösche Zeilen und Spalten i und j aus D
- Füge in D eine Zeile und eine Spalte (ij) hinzu mit $D(ij,k) = (D(i,k)+D(j,k))/2$
- Wiederhole, bis D leer ist

Beispiel


	B	C	D	E
A	8	8	5	3
B		3	8	8
C			8	8
D				5



	BC	D	E
A	8	5	3
BC		8	8
D			5




	BC	D
AE	8	5
BC		8




Beispiel

	AE	BC	D
AE		8	5
BC			8



	BC
AED	8




Kontrolle

	B	C	D	E
A	8	8	5	3
B		3	8	8
C			8	8
D				5

Anwendungsbeispiel

- Sequenzierung der mitochondrialen DNA (16 KB) von 86 geographisch verteilt lebenden Personen
- Ergebnis: Mitochondriale DNA scheint nach einer molekularen Uhr abzulaufen; Divergenz ist ca. 1,7E-8 pro Base und Jahr



Quelle:

Ingman, M., Kaessmann, H., Pääbo, S. & Gyllensten, U. (2000)
Nature 408: 708-713

Quelle:

<http://www.genpat.uu.se/mtDB/sequences.html>


Methode: UPGMA

Wo UPGMA irrt

Der echte Baum

	B	C	D
A	6	8	12
B		4	8
C			6
D			


Was erzeugt UPGMA?



Wo UPGMA irrt


Der echte Baum

	B	C	D
A	6	8	12
B		4	8
C			6
D			




Was erzeugt UPGMA?

	B	C	D
A	6	8	12
B		4	8
C			6



	A	BC	D
A		7	12
BC			7


	A
BCD	9.5



Additive Bäume

- Ultrametriken berechnen im Kern die Label der inneren Knoten
 - Und dadurch kann man Kanten nur auf bestimmte Weisen aufteilen
- Besser: Additive Bäume
 - Bäume mit **Labeln auf den Kanten**
- Eingabe ist wieder eine Ähnlichkeitsmatrix
 - Die Werte in der Matrix sind nicht direkt die Kantenlabeln, sondern Längen von Pfaden im Baum
 - Abstände enthalten sich gegenseitig
- Da es nur Abstände gibt, hat der Baum **keine Wurzel**
 - Gesucht ist eine Anordnung so, dass die Pfade im Baum die „richtigen“ Längen haben

	B	C	D
A	6	8	12
B		4	8
C			6
D			



Additive Bäume

- Definition

Sei D eine symmetrische Matrix mit n Spalten und Zeilen (und nur positiven Werten; $D(i,i)=0$). Ein Baum T mit Kantenlabeln heißt additiver Baum für D , wenn gilt

- T hat n Blätter, beschriftet mit den Zeilen von D
- Für jedes Paar i,j ist $D(i,j)$ gleich der Summe der Kantenlabel auf dem (eindeutigen) Pfad von i nach j

- Bemerkung

- Jede ultrametrische Matrix induziert einen additiven Baum aber nicht umgekehrt


4-Punkt Bedingung

- Theorem


*Eine Matrix D hat einen additiven Baum gdw. für alle Zeilen i, j, k, l die **4-Punkt Bedingung** gilt:*

$$D(i,k) + D(j,l) \leq \max(D(i,j) + D(k,l) , D(i,l) + D(k,j))$$

- Beweis: Literatur



$$(a+b) + (e+f) \leq \max((b+c+e) + (a+c+f), (b+c+f) + (a+c+e))$$



$$(b+c+f) + (a+c+e) \leq \max((a+b) + (e+f), (b+c+e) + (a+c+f))$$

Neighbor-Joining

- Matrizen und Algorithmen
 - Ultrametrische Matrizen – UPGMA
 - Additive Matrizen – Neighbor Joining
- Hierarchisches Clusterverfahren (wie UPGMA)
 - Erzeugt einen binären Baum ohne Wurzel
 - Grundaufbau wie UPGMA
 - Beginne mit so vielen Clustern wie Blättern
 - Wähle nach bestimmtem Kriterium zwei Cluster
 - Verschmelze die zwei Cluster und verbinde Knoten im Baum
 - Iteriere, bis nur noch ein Cluster vorhanden ist
- Unterschiede
 - UPGMA wählt Cluster zur Verschmelzung nur nach Nähe zueinander
 - Neighbor Joining wählt Cluster nach der Nähe zueinander und dem Abstand zu anderen Clustern

Weitere Algorithmen

- Maximum parsimony
 - Character-based
 - Jedes Zeichen einer Zeichenkette / jedes Merkmal wird verwendet, um innere Knoten zu beschriften
 - Small parsimony
 - Vorgegebener Baum
 - Berechnet die besten inneren Sequenzen
 - Fitch's Algorithmus
 - Large parsimony
 - Berechne Baum und innere Sequenzen
 - Branch & Bound

Vergleich

- Man liest häufiger, dass alle Phylogeniemethoden recht gut funktionieren
 - Gilt nur bei einfachen **Evolutionsmodellen**
 - Güte hängt von den Eigenschaften der Daten ab
- Distanzbasierte Methoden: Am ungenauesten, dafür schnell
- Maximum Parsimony: Besser, aber sehr teuer
- **Maximum Likelihood**: Noch besser, noch viel teurer
- Also: Mehrere Methoden vergleichen
 - Gruppen, die überall gleich sind, gelten als sehr robust
 - „**Consensus tree**“